



研究与开发

基于BYOL与实复域融合的动态噪声自动调制识别

赵少坤¹, 贾勇^{1,2}, 张伟^{3,4}, 姚光乐¹, 张建¹

1. 成都理工大学机电工程学院, 四川 成都 610059;
2. 电子科技大学长三角研究院(衢州), 浙江 衢州 324000;
3. 电子科技大学通信与信息工程学院, 四川 成都 611731;
4. 电磁空间安全全国重点实验室, 四川 成都 610036)

摘要: 在复杂电磁对抗场景中, 无线信道的时变噪声干扰和多域耦合效应使测试数据集的噪声分布特性与训练集的先验假设条件发生偏离, 导致神经网络模型出现特征失配, 进而引发基于静态信道假设的调制识别系统在跨域场景中的性能劣化。为应对这一挑战, 提出了一种基于对比学习与实复域融合的动态噪声自动调制识别方法。在预训练阶段, 借助BYOL (bootstrap your own latent) 对比学习框架, 构建实复域融合网络, 强制模型通过自监督学习来深刻理解数据的内在结构, 从而降低特征提取对噪声分布变化的敏感性, 增强模型在不同信噪比条件下的泛化能力; 在微调阶段, 将短时傅里叶生成的复数时频谱输入实复域融合网络, 提取信号的多维特征, 使网络学习到与信道噪声无关的本质特征。综合以上两种策略, 使模型能够有效地应对不同信噪比条件下的动态噪声干扰。实验结果表明, 在待识别信号信噪比下降6 dB的情况下, 所提方法相较于现有视觉变换器 (vision transformer, ViT) 等方法, 识别准确率至少提升了23.98%。

关键词: 对比学习; 特征融合; 动态噪声; 自动调制识别

中图分类号: TN92

文献标志码: A

doi: 10.11959/j.issn.1000-0801.DXKX250549

Automatic modulation classification in dynamic noise based on BYOL and real complex domain fusion

Zhao Shaokun¹, Jia Yong^{1,2}, Zhang Wei^{3,4}, Yao Guangle¹, Zhang Jian¹

1. School of Mechanical and Electrical Engineering, Chengdu University of Technology, Chengdu 610059, China
2. Yangtze Delta Region Institute, University of Electronic Science and Technology of China, Quzhou 324000, China
3. School of Communication and Information Engineering, University of Electronic Science and Technology of China, Chengdu 611731, China
4. National Key Laboratory of Electromagnetic Space Security, Chengdu 610036, China

Abstract: In complex electromagnetic countermeasure scenarios, the time-varying noise interference of wireless

收稿日期: 2025-09-12; 修回日期: 2026-01-26

通信作者: 贾勇, jiaoyong2014@cdut.edu.cn

基金项目: 国家自然科学基金资助项目 (No. U20B2070)

Foundation Item: The National Natural Science Foundation of China (No. U20B2070)

channels and multi-domain coupling effects cause the noise distribution characteristics of the test data set to deviate from the prior assumption conditions of the training set, leading to feature mismatch in deep neural network models and subsequently causing performance degradation of modulation recognition systems based on the static channel assumptions in the cross-domain scenarios. To address this challenge, a dynamic noise automatic modulation recognition method based on contrastive learning and real-complex domain fusion was proposed. In the pre-training stage, the bootstrap your own latent (BYOL) contrastive learning framework was utilized to construct a real-complex domain fusion network, forcing the model to deeply understand the intrinsic structure of the data through self-supervised learning, thereby reducing the sensitivity of feature extraction to the changes in noise distribution and enhancing the model's generalization ability under different signal-to-noise ratio conditions. In the fine-tuning stage, the complex time-frequency spectrum generated by short-time Fourier transform was input into the real-complex domain fusion network to extract the multi-dimensional features of signal, enabling the network to learn the essential features that independent of channel noise. The combination of these two strategies enabled the model to effectively cope with the dynamic noise interference under different signal-to-noise ratio conditions. Experimental results show that when the signal-to-noise ratio of the signal to be recognized decreases by 6 dB, the proposed method achieves at least a 23.98% improvement in recognition accuracy compared with the existing methods, such as vision Transformer (ViT).

Key words: contrastive learning, feature fusion, dynamic noise, automatic modulation classification

0 引言

自动调制识别技术通过分析接收到的无线信号的特征,识别信号的调制类型,从而有助于信号解调、信号分析、频谱管理以及干扰检测等操作^[1]。在军用和民用领域具有重要的研究意义和实用价值^[2]。在实际环境中,自动识别技术通常面临动态噪声的场景^[3-4]。例如,在军用领域中,战术调频通信通过频繁切换频率导致接收端信噪比动态变化^[5]。在民用领域中,车载通信、高铁、无人机群组网等移动通信场景中,收发端高速移动也会导致多普勒频移和时变信噪比^[6-8]。

目前,动态噪声环境中的自动调制识别依然是一个重要挑战。传统的调制识别方法主要包括基于似然函数和基于特征的识别方法。前者依赖先验知识且计算复杂度较高,而后者虽然提高了计算效率,但在时变信道中容易受到特征分布偏移的影响,导致识别准确率降低^[9-10]。现有的深

度学习方法虽然在固定噪声条件下取得了显著的进展,但大多数研究假设噪声环境是固定的,这导致在面对时变信噪比或者动态噪声的场景时,模型的性能明显下降^[11]。文献[12]采用迁移学习和领域自适应相结合的方法,实现了不同信噪比条件下信号特征的统一映射,并利用ResNet完成动态噪声环境中的通信辐射源识别。文献[13]提出了一种基于信噪比分类的预处理方法,通过构建信噪比判别网络对输入信号进行高低信噪比划分,并对低信噪比样本进行增强处理后再送入识别网络进行特征提取。但是,网络算法复杂度高并且不能很好地区别16QAM信号和64QAM信号,WBFM信号和AM-DSB信号,具有一定的局限性。文献[14]通过显式的建模和剥离信号中的环境扰动(相位偏移)来强化模型对本质身份特征的学习能力,从而极大地提升了在变化环境下的识别鲁棒性。文献[15]使用多个并行的子网络分别处理不同来源、不同类型的输入数据,引入注意力网络评估每个数据源所



提取特征的重要性，最后将所有源的加权特征进行加权求和，得到一个强化的融合特征表示，用来解决复杂多变实际环境中的识别任务。文献[16]构建了一个I/Q交互增强自动编码器，显式地使I路和Q路的特征在模型的早期阶段就进行充分的交互和融合，模拟I/Q信号在复数域中固有的耦合关系，相较于将I/Q两通道简单拼接起来，识别率在所使用的数据集上最高可以提升5.36%。

在这一背景下，自动调制识别的关键问题是如何提升模型在变化信道环境中的鲁棒性，特别是如何减弱信道噪声对特征学习的干扰，并保持高准确度。现有的解决方案多依赖于数据增强或特定噪声模型的引入，但通常仍然局限于静态或有限的噪声条件下^[17-18]。

针对这一问题，本研究应用 bootstrap your own latent 自监督对比学习范式。首先，设计了一种实部与虚部联合的特征提取网络，采用无监督训练方式增强模型对信号本质特征的捕获能力，有效地克服了噪声扰动导致的特征失真问题，从而确保模型在复杂噪声条件下仍具有稳定的识别性能。其次，实复域融合网络通过同时提取并融合信号在实数域和复数域中的特征，进一步提升了模型的多域学习能力，增强了其对信道噪声的抗干扰能力。通过这种方法，模型能够在信噪比变化和噪声环境动态变化的条件下，保持高准确率的识别性能。本文基于公开数据集 RadioML2016.10a^[19]和 RML22^[20]进行仿真验证，实验结果表明，所提方法在动态噪声环境中显著地提升了调制信号的分类精度。

1 问题描述与相关工作

1.1 信号建模

信号调制技术实现了基带信号向高频载波的转换，以适应信道传输需求。各类调制方式呈现独特的特征，如幅度调制（amplitude modulation, AM）中载波幅度随调制信号变化，但频率保持恒定，正交振幅调制（quadrature amplitude modulation, QAM）同时改变载波的幅度和相位，相移键控（phase-shift keying, PSK）信号的相位在有限个离散值之间切换，用于表示数字信息，频移键控（frequency-shift keying, FSK）用不同的频率表示二进制0/1，差分相移键控（differential phase-shift keying, DPSK）通过相邻符号的相位差传递信息^[21]，利用这些差异可以识别不同的调制类型。本文考虑的是单输入单输出通信系统，接收信号可表示为^[22]：

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

其中， $s(t)$ 是来自发射机的调制信号， $*$ 代表卷积运算， $h(t)$ 是信道脉冲响应， $n(t)$ 表示加性高斯白噪声。接收信号 $r(t)$ 通过模数转换器以 $f_s = 1/T_s$ 的频率采样 n 次，产生离散时间观测信号 $r(n)$ 。

利用短时傅里叶变换（short-time Fourier transform, STFT）对信号进行时频分析，实现了信号从时域到时频域的转换，同时获取信号在时域和频域的联合分布特征。STFT的基本思想是通过滑动一个窗函数，对信号进行局部分析。对于一个连续的时域信号 $r(t)$ ，STFT的数学表达式为：

$$R(t, f) = \int_{-\infty}^{\infty} r(\tau) w(\tau - t) e^{-j2\pi f \tau} d\tau \quad (2)$$

其中， $w(\tau - t)$ 是窗函数， $e^{-j2\pi f \tau}$ 是傅里叶变换核， $R(t, f)$ 为输出的时频谱。时频谱 $R(t, f)$ 是一个复数矩阵，其中，每个元素表示信号在特定时刻 t 和频率 f 下的复数值，不仅包含了信号的幅度信息，同时携带了相位信息。

1.2 相关工作

对比学习属于典型的自监督学习范式^[23]，核心机制是通过构建正负样本对来建模样本间的相

似关系，促使网络在嵌入空间中同类样本的特征向量聚集，同时拉大异类样本的特征距离。这种过程强制模型能够有效地提取出数据的隐式特征，即那些并不显式标注但对数据本质具有重要意义特征^[24]。

不同的调制方式，通过改变载波的幅度、频率、相位来编码信息，这些变化在时频域中会形成独特的“指纹”。在实部、虚部这两个通道中，包含由调制方式决定的、在时频平面上展现的、卷积神经网络（convolutional neural network, CNN）可提取的“幅度纹理”。但这种拆分方式会破坏复数内在的、严格的复数代数关系（比如，一个复数乘以另一个复数，几何意义是旋转和缩放，这在实数卷积中难以精确表达）。因此，更侧重于幅度信息的提取，而对相位信息的捕捉是间接且不完整的。复数运算保持了幅度与相位之间的耦合关系，能够捕捉到信号中诸如相位延迟、正交分量相关性等特征，并且，如果不设计复数网络，粗暴地将复数矩阵直接输入实数网络中，是在强迫模型处理不擅长的复数关系问题，结果是没有利用好复数信息，并且也无法达到优化后的实数分支在幅度纹理上提取的性能。

本文采用BYOL自监督学习架构，摒弃了传统对比学习对负样本的依赖，转而通过单样本多视角特征对齐实现模型优化。该方法通过最大化同一信号不同增强版本的特征一致性有效地缓解了传统方法中噪声干扰导致的模型退化现象。复值信号包含实部和虚部的信息以及二者之间的相关性，可以反映信号的幅度、频率、相位等特征。而实值网络通常会丢失这些信息^[25]。因此，可以在对比学习的架构中，将传统实值网络模型与复值网络模型融合。本文运用实复域联合约束办法，切实提高了判别信息的提取能力，抑制了噪声隔离对识别准确性的负面影响，在动态噪声环境中实现了信号识别

精度的提升。

2 对比学习与实复域融合的自动调制识别方法

无线信道的时变噪声干扰与多域耦合效应会引发深度神经网络模型的特征偏移，使基于静态信道假设的调制识别系统出现跨域性能劣化^[26-27]。

针对该问题，本文提出了一种结合对比学习与复数域特征融合的自动调制识别算法。系统模型如图1所示，对输入信号进行STFT获取复数时频表征 $R(t, f)$ ，在预训练阶段使用海量且易得的无标签数据，使模型从海量数据中学习通用模式，迫使模型关注数据本身的内在结构，识别出哪些特征是不变的，哪些语义是核心的。通过自监督对比学习机制自动提取时频特征的内在表示，进而克服噪声隔离对自动调制识别造成的困难，微调阶段使用有标签的数据，将在预训练中学到的通用知识，迁移并适应到一个特定的、有标签的任务上。具体来说，将时频谱矩阵输入实复域融合网络中，分别提取实数域特征以及复数域特征，将实数域特征与复数域特征融合，捕捉信号多维信息之间的内在关联，充分利用两域特征的互补性和相关性，实现对其他信噪比下信号的准确识别。在识别阶段，利用微调后的特征提取网络和分类器实现信号调制方式的自动判别。

2.1 实复域融合神经网络

在信号识别领域，CNN和长短期记忆（long short-term memory, LSTM）网络相较于深度神经网络（deep neural network, DNN）展现出更优的性能。CNN通过局部连接特性可有效地提取信号的频域特征，显著降低频率波动的影响；LSTM凭借门控机制能够建模信号序列中的时序依赖关系；DNN擅长将特征转换至线性可分空间。

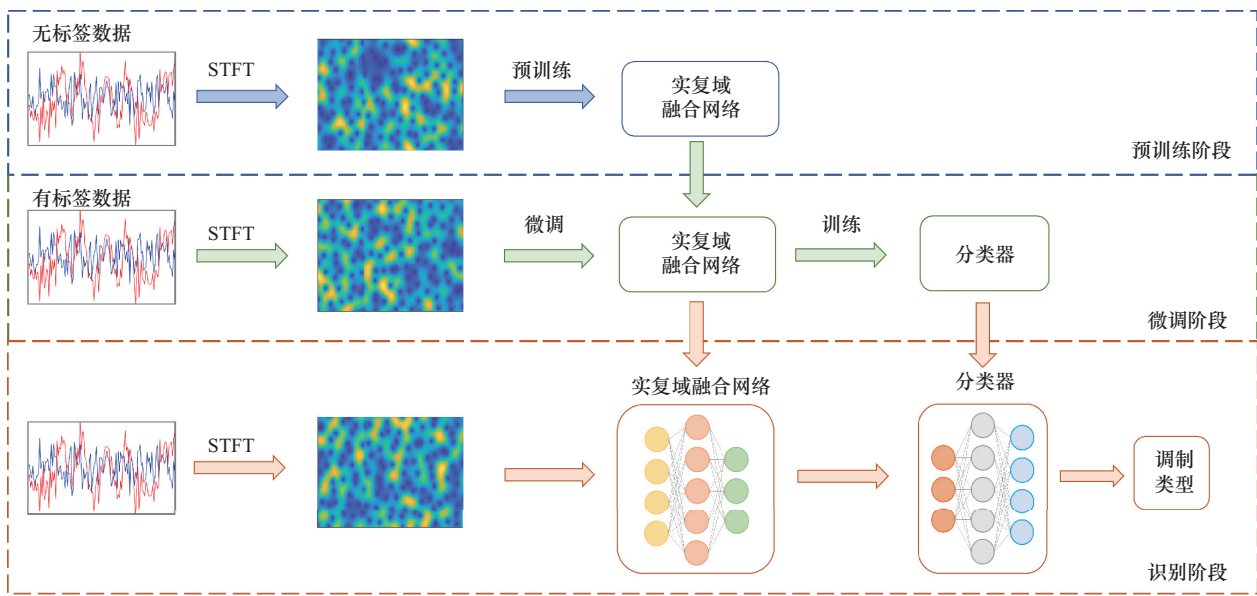


图1 系统模型

卷积长短期记忆深度神经网络 (convolutional LSTM deep neural network, CLDNN) 可以利用 CNN、LSTM 和 DNN 之间的互补性, 通过分层特征抽象机制实现信号时空特征的联合建模。在信号特征提取方面, 卷积层通过可学习的复数域滤波器组对输入信号的时频分量进行稀疏表示, 权值共享机制可有效地抑制带外噪声引起的频率偏移。LSTM 则通过门控单元动态地建模符号间的时间相关性。DNN 的全连接层结构通过非线性映射将联合特征投影到高维正交空间, 完成信号识别任务。CLDNN 模块由 4 个卷积层、2 个 LSTM 层以及 2 个全连接的 DNN 层组成, 每个实卷积层都设置了 3×3 的实值卷积核, 运用 ReLU 非线性激活函数, 并且连接步长是 1 的 2×2 最大池化层, 复卷积层选用的是 3×3 复数卷积核, 也使用 ReLU 激活函数来达成非线性变换, 同时引入了批归一化函数, 以进一步提高网络的训练稳定性和收敛速度。复数时频谱矩阵作为网络的输入, 能够有效地捕捉信号的时频信息, STFT 能够为网络提供局部时间—频率分辨率, 帮助网络捕捉信号在时频域的变化。

在自动调制识别领域中, 接收机所获取到的信号样本, 从本质上来说呈现出复数序列的结构形式, 其中, 每一个样本都由实部以及虚部彼此正交的分量所构成, 这两个分量分别对信号的同相分量以及正交分量的特征维度给予表征。现有模型主要依赖直接将 STFT 得到的时频谱图输入多个实卷积层提取出信号的特征进行信号识别与分类。在信号处理领域, 复数值数据比实数值数据具有更丰富的信息量和更强的特征表征能力。近年来, 基于复数运算的神经网络在信号处理任务中得到了广泛应用。在复值神经网络中, 复数特征以 $\mathbf{R} = \mathbf{X} + i\mathbf{Y}$ 作为输入, 复数卷积核表示为 $\mathbf{W} = \mathbf{A} + i\mathbf{B}$, 将特征图与复值卷积核进行如下卷积操作:

$$\mathbf{W} * \mathbf{R} = (\mathbf{A} * \mathbf{X} - \mathbf{B} * \mathbf{Y}) + j(\mathbf{B} * \mathbf{X} + \mathbf{A} * \mathbf{Y}) \quad (3)$$

可用矩阵形式表示为:

$$\begin{bmatrix} \text{Re}(\mathbf{W} * \mathbf{R}) \\ \text{Im}(\mathbf{W} * \mathbf{R}) \end{bmatrix} = \begin{bmatrix} \mathbf{A} & -\mathbf{B} \\ \mathbf{B} & \mathbf{A} \end{bmatrix} * \begin{bmatrix} \mathbf{X} \\ \mathbf{Y} \end{bmatrix} \quad (4)$$

其中, $\text{Re}(\mathbf{W} * \mathbf{R})$ 为输出特征的实部, $\text{Im}(\mathbf{W} * \mathbf{R})$ 为输出特征的虚部。经过复值卷积后得到的特征图仍为复数, 避免了将复数拆分为实部和虚部所导

致的信息丢失问题。

在复数运算的全连接层中，权重 W 与数据 R 间的运算过程为：

$$WR = (AX - BY) + j(BX + AY) \quad (5)$$

可用矩阵形式表示为：

$$\begin{bmatrix} \text{Re}(WR) \\ \text{Im}(WR) \end{bmatrix} = \begin{bmatrix} A & -B \\ B & A \end{bmatrix} \begin{bmatrix} X \\ Y \end{bmatrix} \quad (6)$$

因此，本文分别使用基于实值操作的 CLDNN 以及基于复值操作的复值神经网络通过并行学习的模式相互补充，一个侧重于提取复数时频谱矩阵中实部与虚部之间的结构信息，另一个侧重于提取时频谱本身实部和虚部之间的复关系信息，共同构成实复域融合神经网络。可完整保留时频谱的幅度—相位联合信息，用于动态噪声场景中的调制识别。

本文从信号多域特性挖掘的角度切入，研究在复杂噪声背景下更具鲁棒性的特征提取方法，以应对测试信号与训练数据在信道噪声条件下存在差异的问题。实复域融合网络如图 2 所示，本文提出了一种融合实数域与复数域特征提取的混合网络架构。通过设计复卷积运算模块，结合传统卷积与时间序列建模的优势，构建了实数—复数联合特征提取网络。该方法有效地解决了传统实值网络在处理复数信号时存在的相位信息丢失

和相位不连续问题，在低信噪比环境中实现了信号识别性能的显著提升。

2.2 数据增强

预训练阶段的本质是一个针对两种增强视图的自监督对比学习过程。通过对未标记数据进行数据增强，鼓励模型学习不随数据增强变换而改变的特征表示。然而，简单的数据增强无法帮助模型学习有用的信息，过于复杂的数据增强会引入大量噪声，使模型的收敛变得困难。因此，数据增强方法的选择和设计至关重要，本文采用双空间数据增强策略，通过在样本空间和特征空间同时实施增强操作来优化训练数据质量。

基于样本空间的常见增强：本文引入旋转和翻转两种方法，这两种方法都是在样本空间上的直接变换。对于时频谱 $R = X + iY$ ，旋转增强可以表示为：

$$G_r(R, \sigma) = \begin{bmatrix} \cos\sigma & -\sin\sigma \\ \sin\sigma & \cos\sigma \end{bmatrix} \begin{bmatrix} X \\ Y \end{bmatrix} \quad (7)$$

其中， σ 为旋转角度，本文从 $\{0, \pi/2, \pi, 3\pi/2\}$ 中随机选取。对于每一个样本，随机选择 4 次旋转或者 2 次翻转， $G_{f-h}(R)$ 为水平翻转， $G_{f-v}(R)$ 为垂直翻转，作为样本空间的增强方法 $G_{CA}(\cdot)$ ，可以被表示为：

$$G_{CA}(R) \in \{G_r(R, \sigma)\} \cup \{G_{f-h}(R), G_{f-v}(R)\} \quad (8)$$

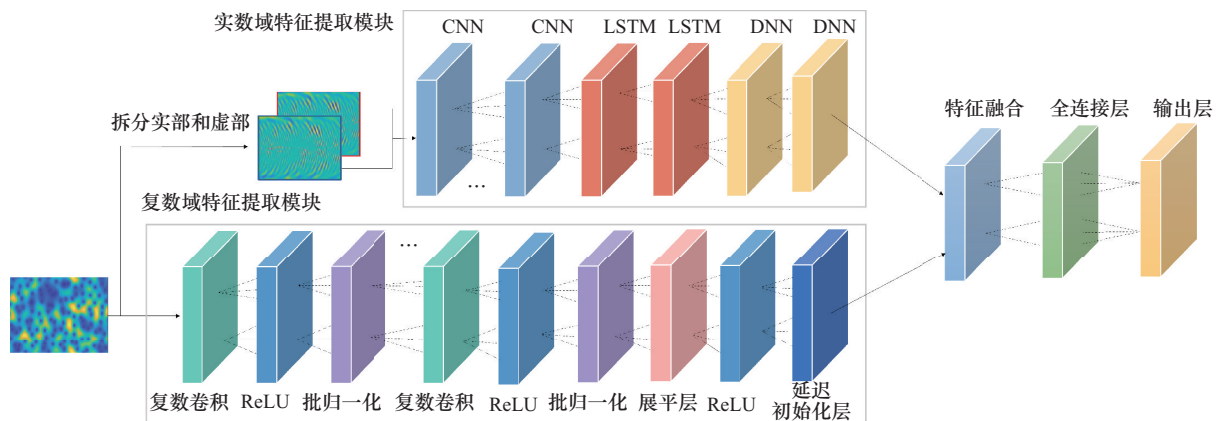


图2 实复域融合网络



基于特征空间的增强方法：Adv-Aug。Adv-Aug通过对信号的特征应用偏移来变换信号，然后通过编码器 f_θ 将这个添加偏移的特征反向映射到原始信号。Adv-Aug中的“对抗性”主要体现在特征偏移的强度上。用于自动调制识别的BYOL如图3所示，首先，生成与输入样本相同的随机扰动 r ，然后将 R 和 $R+r$ 输入编码器 f_θ 中以获得特征表示 $z=f_\theta(R)$ 和 $z^*=f_\theta(R+r)$ ， k 指代输入的数据。以 z 和 z^* 的均方误差作为距离测度 \mathcal{D} ，找到可以最大化 \mathcal{D} 的扰动 r ，该方法主要针对的是特征的对抗性偏差。训练过程中随着 f_θ 的更新，同一数据的特征也在发生变化，因此Adv-Aug是动态的。Adv-Aug定义为：

$$G_{AA}(f_\theta; R) = R + r_A \quad (9)$$

最终预训练阶段 R 的混合数据增强表示为：

$$G_{HA}(f_\theta; R) = G_{AA}(f_\theta; G_{CA}(R)) \quad (10)$$

2.3 用于自动调制识别的BYOL对比学习框架

用于自动调制识别的BYOL有两个网络：目标网络和在线网络，两个网络相互作用并相互学习。在线网络主要通过预测目标信号表征来训

练新的和潜在的增强表征。目标网络主要服务于在线网络，为在线网络提供目标信号表示。本文使用BYOL进行无线信号调制识别分3步进行，首先，在预训练阶段使用大量未标记样本对网络进行预训练，以获得编码器的初始权重。然后，在下游任务使用标记样本传入编码器。最后，将训练好的编码器和分类器用于信号调制识别。

在预训练阶段，用于自动调制识别的BYOL如图3所示，对 $R \sim D_{au}$ 进行两次数据增强 $\{t, t'\} \sim \mathcal{T}$ ，得到增强视图 $v = t(R)$ 和 $v' = t'(R)$ ，其中， \mathcal{T} 包含常见的旋转、翻转以及Adv-Aug方法。在线网络由编码器 f_θ 、投影器 g_θ 和预测器 q_θ 组成，参数为 θ ，目标网络由编码器 f_ξ 和投影器 g_ξ 组成，参数为 ξ 。因此，通过在线网络和目标网络的前向传播，可以分别得到输出 $p = q_\theta(g_\theta(f_\theta(v)))$ 和 $s' = g_\xi(f_\xi(v'))$ 。然后对 p 和 s' 执行 l_2 正则化。最后，将 p 和 s' 的均方误差定义为损失函数 \mathcal{L}_{mse} ，表示为：

$$\mathcal{L}_{mse} = \|\bar{p} - \bar{s}'\|_2^2 = 2 - 2 \times \frac{\langle p, s' \rangle}{\|p\|_2 \cdot \|s'\|_2} \quad (11)$$

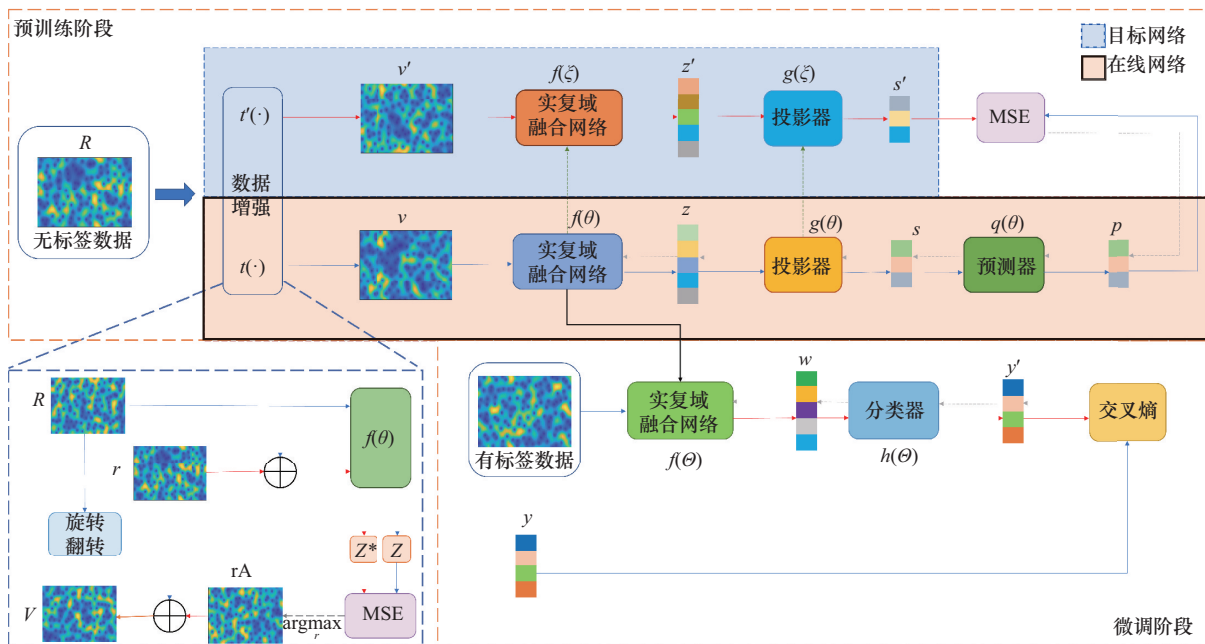


图3 用于自动调制识别的BYOL

在微调阶段, 可以将预训练阶段获得的编码器 f_θ 迁移并用作初始特征提取器 f_θ 。具体来说, 正是将参数 θ 共享给 Θ 才实现了知识的迁移。只需要添加一个分类器 h_θ , 然后就可以用标记数据对其进行微调。分类器的输出可以表示为 $u = \mathcal{F}(R; W)$ 。与随机初始化相比, 通过知识迁移初始化可以克服样本依赖性的限制, 帮助模型更快收敛。

在识别阶段, 将在微调阶段获得的编码器和分类器应用在网络中, 用于自动调制识别。

3 实验分析

3.1 数据集

本实验基于调制信号数据集RML2016.10a^[19]和RML22^[20]展开, RML2016.10a支持可变信噪比场景, 涵盖多种调制类型。具体而言, 包含8类数字调制类型: 二进制相移键控(binary phase shift keying, BPSK)、正交相移键控(quadrature phase shift keying, QPSK)、八相相移键控(8-ary phase shift keying, 8PSK)、连续相位频移键控(continuous phase frequency shift keying, CPFSK)、高斯频移键控(Gaussian frequency shift keying, GFSK)、四电平脉冲幅度调制(4-level pulse amplitude modulation, PAM4)、16进制正交幅度调制(16-ary quadrature amplitude modulation, 16QAM)和64进制正交幅度调制(64 quadrature amplitude modulation, 64QAM), 以及3类模拟调制类型: 幅度调制-双边带(amplitude modulation - double sideband, AM-DSB)、幅度调制-单边带(amplitude modulation-single sideband, AM-SSB)和宽带调频(wideband frequency modulation, WBFM)。每类调制信号对应20个不同的信噪比水平, 范围为-20 ~ 18 dB, 步长为2 dB, 组合总数达到220种。每条信号样本长度为128点, 数据维度为 $1 \times 2 \times 128$ 的格式进行组织与存储。类似地, RML22相较于

RML2016.10a缺少了AM-SSB的调制信号, 使用USRP和LimeSDR等软件无线电设备实际发射和接收信号。数据来自大量独立的发射-接收事件。构建实验所使用的训练集和测试集的过程如下: 对数据集中的信号样本做STFT, 得到复数时频谱矩阵数据集, 再基于相同信噪比按8:2的比例随机划分为训练子集和测试子集, 以构建动态噪声场景。动态噪声场景中的识别性能验证实验选择信噪比(signal to noise ratio, SNR)范围在-12 ~ 12 dB的训练子集和验证子集。

3.2 参数设置

网络结构见表1, 本文在编码器 f_θ 中堆叠了9个复值卷积层, 卷积步长设置为2, 可以得到维度为1 024的信号特征。在投影器中, 信号特征的维度降低到128。在预测器中, 通过升维和降维来保持维数不变。在分类器中, 全连接层可以将提取到的1 024维特征映射为11类调制类型的概率。本研究中所有识别模型均采用交叉熵损失函数(cross-entropy loss, CE Loss)作为目标函数。在模型训练过程中, 选用Adam优化器进行迭代更新, 初始学习率设为0.001, 批量大小设定为64。全部实验均基于PyTorch框架完成, 由NVIDIA CUDA平台提供计算支持, 所使用的图形处理器为GeForce RTX 4080 GPU。

3.3 动态噪声场景中模型性能验证

在自动调制识别研究中, 通常使用ResNet的结果作为评估性能的“最下限”, 并且可以代表一部分实数网络模型的性能; 视觉变换器(vision transformer, ViT)通过自注意力机制捕获图像中的全局上下文关系, 通过对比可以探究对于时频矩阵来说, 只考虑全局信息以及局部和全局信息融合, 哪种模型构建思路更具优势; 由于调制信号本质上也是时间序列, 因此会使用LSTM来捕捉时间上的长期依赖关系; 在自动调制识别领域中, CLDNN作为在实数域内进行时空特征融合的基线模型, 用来验证针对动态噪声场景中



表1 网络结构

| 模块 | 架构 | 层数 |
|-------|----------------------------|----|
| 复数编码器 | 复数卷积层+线性整流单元+批归一化 | 9 |
| | 展平层 | 1 |
| 投影器 | 惰性初始化线性层 (1 024)+线性整流单元 | 1 |
| | 惰性初始化线性层 (512)+批归一化+线性整流单元 | 1 |
| | 惰性初始化线性层 (128) | 1 |
| 预测器 | 惰性初始化线性层 (512)+批归一化+线性整流单元 | 1 |
| | 惰性初始化线性层 (128) | 1 |
| 分类器 | 惰性初始化线性层 (11) | 1 |

的自动调制识别，“实—复域特征融合”这一新范式与“时—空特征融合”哪个更有效。单独的复数网络其实是作为“复数域处理”的消融实验基准，通过与实数网络的对比验证复数域处理的优势，通过与本文模型对比验证实—复域特征融合的优势。

因此，本文基于RML2016.10a和RML22两个数据集设计了以下两组对比实验：第一组将带标签且信噪比为4 dB的信号设为源域，第二组则选取信噪比为0 dB的带标签信号作为源域，目标域均为不同信噪比且不含标签的信号样本，分别使用本文提出的模型及5种对照模型进行训练与测试，最终对6种模型对调制信号的特征提取效果进行了可视化分析，并对比了各模型在目标域信号识别准确率方面的表现。

信噪比为4 dB信号作为源域的识别性能对比如图4所示，在公开数据集RML2016.10a上进行的实验中，5种对比模型的识别性能随信噪比降低而显著恶化。当测试信噪比降至-6 dB以下时，各模型准确率普遍跌落至11.3%左右，这验证了高信噪比训练模型在低信噪比环境下的特征提取失效问题。相较之下，本文所提方法展现出了更优的环境适应能力。当目标域信噪比为-2 dB时，本文模型的识别准确率提升最显著，性能增益达到28.97%。




图4 信噪比为4 dB信号作为源域的识别性能对比

各模型在信噪比为0 dB时的潜在分布如图5所示，实验对比了6种模型在源域（4 dB）和目标域（0 dB）信号下的特征空间分布。结果显示，由于信噪比差异导致的特征偏移，各模型提取的特征存在显著重叠，严重影响了调制类型的判别性能。在信道环境噪声不一致的情况下，本文模型依旧可以提取到有用的特征（图中椭圆圈标注部分展现出了更好的可分性），以识别各种不同的调制类型，可以有效地提取出可分性好的噪声鲁棒性特征。而其余5种模型识别性能均明显下降，无法进行有效识别。

为了进一步分析实验结果，信噪比为0 dB信号作为源域的识别性能对比如图6所示，对比信噪比为0 dB信号作为源域时的识别准确率，当目标域信噪比低于-6 dB时，模型可以抑制部分干扰，但受限于源域和目标域联合分布差异，效

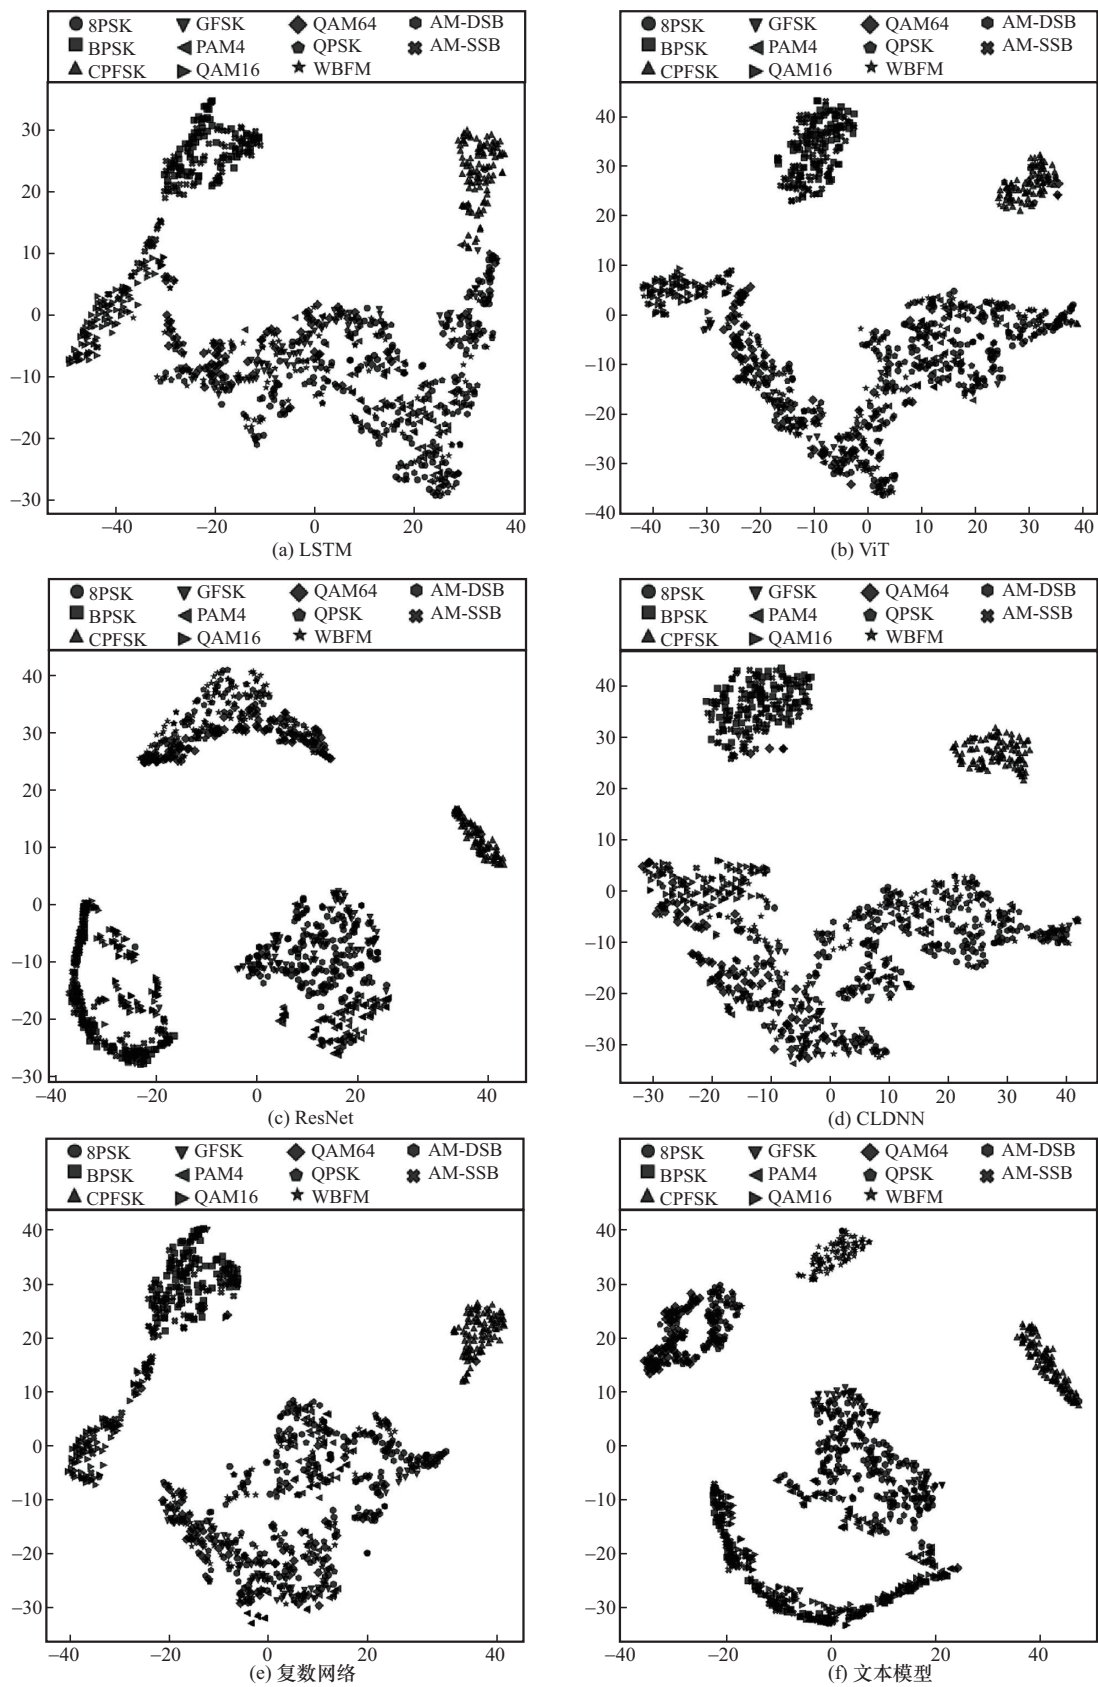


图5 各模型在信噪比为0 dB时的潜在分布



果并不明显,当信噪比为 $-6 \sim 4$ dB时,一方面由于网络提取了信号的相位信息,增强了对噪声干扰的鲁棒性表征,另一方面BYOL对比学习框架的动量更新机制构建了稳定的对比关系,使模型能够学习到与噪声无关的本质特征。




图6 信噪比为0 dB信号作为源域的识别性能对比

在信噪比大于4 dB之后,两组实验的识别准确率均保持稳定。这是因为当目标域信噪比超过阈值时,信号特征的信道容量趋于饱和,信息熵增量不足以驱动模型进一步优化决策边界。在某些特定信噪比下,本文方法识别准确率较传统方法出现了下降,这种现象是因为两者目标场景的优化目标不同,低信噪比场景中,模型需要最大化同类信号在不同噪声下的特征一致性,而高信噪比场景中模型需要最大化不同调制信号的特征距离,通过监督学

习直接优化分类边界,由于高信噪比下信号较清晰,本文方法的复杂结构也会导致过拟合。

为进一步验证模型的泛化能力,本文在RML22数据集上也进行了相同的测试。该数据集的调制信号来自大量独立的发射—接收事件,模拟了真实世界的分布变化,还引入了脉冲噪声,为数据带来了非平稳、突发性的挑战。RML2016.10a对比实验结果见表2、RML22对比实验结果见表3, RML22的所有模型绝对性能相较于RML2016.10a均有所下降。尽管如此,本文模型相较于基线模型依然可以保持最高的准确率,这一结果说明,本文模型不仅适用于特定场景,对于分布外或更复杂的未知数据也具备优异的鲁棒性。

3.4 消融实验

所提出的方法为了提高动态噪声场景中模拟的识别性能主要通过构建“实—复域融合”这一新范式融合数据的幅度纹理及复数全局特征,充分利用数据的内在特征。下面开展消融分析实验来评估这一改进对模型整体性能的提升。具体来说,在微调阶段,分别仅保留实数分支和只保留复数分支与本文模型性能进行对比。分别使用RML2016.10a和RML22两个数据集,信噪比范围为 $-4 \sim 4$ dB,以信噪比为4 dB的信号作为源域。消融实验结果见表4。

表2 RML2016.10a对比实验结果

| 训练集信噪比/dB | 测试集信噪比/dB | RML2016.10a | | | |
|-----------|-----------|-------------|--------|--------|--------|
| | | LSTM | ViT | ResNet | 本文模型 |
| 4 | -4 | 12.20% | 13.04% | 13.70% | 32.50% |
| | -2 | 16.17% | 15.71% | 16.21% | 44.68% |
| | 0 | 32.22% | 34.51% | 36.21% | 71.00% |
| | 2 | 58.15% | 57.05% | 63.10% | 82.59% |
| | 4 | 84.91% | 85.60% | 83.87% | 87.90% |
| 0 | -4 | 10.20% | 11.04% | 10.70% | 30.50% |
| | -2 | 14.37% | 13.91% | 14.41% | 39.15% |
| | 0 | 41.22% | 46.51% | 50.21% | 73.50% |
| | 2 | 55.15% | 54.05% | 60.10% | 79.59% |
| | 4 | 80.00% | 82.00% | 82.00% | 85.90% |

表3 RML22对比实验结果

| 训练集信噪比/dB | 测试集信噪比/dB | RML22 | | | |
|-----------|-----------|--------|--------|--------|--------|
| | | LSTM | ViT | ResNet | 本文模型 |
| 4 | -4 | 11.30% | 11.80% | 12.50% | 31.20% |
| | -2 | 15.80% | 15.62% | 16.13% | 43.21% |
| | 0 | 32.13% | 33.30% | 34.70% | 69.88% |
| | 2 | 57.40% | 56.88% | 62.00% | 82.08% |
| | 4 | 83.28% | 83.97% | 82.28% | 87.66% |
| 0 | -4 | 10.14% | 10.88% | 10.53% | 29.67% |
| | -2 | 12.12% | 12.18% | 12.28% | 36.72% |
| | 0 | 44.69% | 48.93% | 40.13% | 71.78% |
| | 2 | 51.81% | 57.73% | 53.95% | 77.32% |
| | 4 | 78.99% | 81.03% | 80.58% | 84.10% |

表4 消融实验结果

| 数据集 | 训练集信噪比/dB | 测试集信噪比/dB | 仅实数分支 | 仅复数分支 | 实复域融合 |
|-------------|-----------|-----------|--------|--------|--------|
| RML2016.10a | 4 | -4 | 15.50% | 16.80% | 32.50% |
| | | -2 | 19.21% | 20.70% | 44.68% |
| | | 0 | 41.29% | 48.28% | 71.00% |
| | | 2 | 66.60% | 68.60% | 82.59% |
| | | 4 | 86.11% | 86.50% | 87.90% |
| RML22 | | -4 | 14.00% | 15.80% | 31.20% |
| | | -2 | 18.93% | 20.40% | 43.21% |
| | | 0 | 39.90% | 45.28% | 69.88% |
| | | 2 | 66.58% | 67.38% | 82.08% |
| | | 4 | 86.30% | 85.77% | 87.66% |

对比表4中的信息可以获得以下两方面的信息：首先，相较于实数域来说，复数域对时频矩阵的识别效果更高，这说明严格的复数代数关系在经过拆分为实数之后会使识别性能下降；其次，将实数域的局部纹理以及复数域的全局特征融合之后，帮助了动态噪声下的自动调制识别，这证明了这种“实—复域融合”的新范式在解决动态噪声背景下的自动调制识别问题时是有用的。

3.5 模型抗噪性能验证

为评估各模型在低信噪比环境中的识别性能，本文在公开调制信号数据集RML2016.10a上绘制了LSTM、CLDNN、ViT、ResNet、复值模型以及本文方法的识别准确率曲线，分析各类模

型对整体信号信息的挖掘与表征能力。在相同的SNR条件下，模型提取有用特征的能力越强，所得信号特征分布的可分性越好，进而在识别精度曲线中体现出更高的准确率表现。

不同信号识别模型的识别精度曲线如图7所示，展示了本文所提方法与5种基准模型在RML2016.10a数据集上的性能对比曲线。实验数据显示，所有模型在该数据集上表现出相似的趋势特征：在低信噪比区域（SNR<-4 dB），由于噪声主导信号特征，各模型的识别准确率均接近随机猜测水平；当中等信噪比时（-4 dB<SNR<10 dB），模型开始展现区分能力，准确率呈线性增长态势；在高信噪比区域（SNR>10 dB），各模型的性能提



升幅度逐渐减小, 最终达到饱和状态。本方法在所有信噪比区间均保持相对优势。

当 SNR 处于 $-12 \sim 2$ dB 时, 本文所提模型 (五角星曲线) 的整体识别效果优于其他 5 类方法。本文模型的性能曲线整体高于对照模型, 且在 0 dB 信噪比下, 对测试信号的识别准确率达到 73.5%。




图7 不同信号识别模型的识别精度曲线

4 结束语

为解决训练数据与测试数据信道噪声失配导致的调制识别性能退化问题, 本文创新性地提出了一种融合对比学习和复数域特征融合的鲁棒识别算法。实验结果表明, 该方案在低信噪比条件下保持优异的识别准确率, 对信道环境变化和信噪比波动展现出卓越的适应能力, 为复杂电磁环境中的调制识别系统设计提供了新的技术路径和实践参考。然而, 该方法对极端信噪比 (如 -10 dB 以下) 条件下的信号识别效果仍有待提升。

参考文献:

[1] 刘京华, 魏祥麟, 范建华, 等. 基于时序深度残差收缩网络的混叠信号调制识别方法[J]. 电信科学, 2024, 40(10): 27-38.
Liu J H, Wei X L, Fan J H, et al. Mixed signal modulation recognition method based on temporal depth residual shrinkage network[J]. Telecommunications Science, 2024, 40(10): 27-38.

[2] 杨颖. 无线信号智能识别方法研究[D]. 成都: 电子科技大学, 2023.
Yang Y. Research on intelligent recognition method of wireless signal[D]. Chengdu: University of Electronic Science and Tech-

nology of China, 2023.

[3] 万进华, 尚俊娜, 张华娣. 基于多通道轻量化的自动调制识别网络[J]. 电信科学, 2025, 41(2): 41-56.
Wan J H, Shang J N, Zhang H D. Automatic modulation recognition network based on multi-channel lightweight[J]. Telecommunications Science, 2025, 41(2): 41-56.

[4] 李欣然, 李春国, 明钰婷, 等. 脉冲噪声环境下的调制识别算法[J]. 信号处理, 2024, 40(8): 1497-1507.
Li X R, Li C G, Ming Y T, et al. Modulation recognition algorithm in impulsive noise environment[J]. Journal of Signal Processing, 2024, 40(8): 1497-1507.

[5] Zhao D, Yang J, Liu H, et al. Specific emitter identification model based on improved BYOL self-supervised learning[J]. Electronics, 2022, 11(21): 3485.

[6] 谭凯文, 高岩, 石坚, 等. 基于DropBlock双模态混合神经网络的无线通信调制识别[J]. 电信科学, 2022, 38(5): 75-86.
Tan K W, Gao Y, Shi J, et al. Wireless communication modulation recognition based on DropBlock bimodal hybrid neural network[J]. Telecommunications Science, 2022, 38(5): 75-86.

[7] 杨发权, 李赞, 罗中良. 基于一阶循环均值算法的VHF频段信号调制分类识别方法研究[J]. 电信科学, 2014, 30(2): 76-81.
Yang F Q, Li Z, Luo Z L. Research on modulation classification and recognition method for VHF band signals based on first-order cyclic mean algorithm[J]. Telecommunications Science, 2014, 30(2): 76-81.

[8] Xu J, Luo C, Parr G, et al. A spatiotemporal multi-channel learning framework for automatic modulation recognition[J]. IEEE Wireless Communications Letters, 2020, 9(10): 1629-1632.

[9] 孙妹君, 彭盛亮, 姚育东, 等. 基于深度学习的调制识别综述[J]. 电信科学, 2021, 37(5): 82-90.
Sun S J, Peng S L, Yao Y D, et al. A survey of modulation recognition based on deep learning[J]. Telecommunications Science, 2021, 37(5): 82-90.

[10] Pan Y, Yang S, Peng H, et al. Specific emitter identification based on deep residual networks[J]. IEEE Access, 2019, 7: 54425-54434.

[11] Tang H, Li T, Qiu T, et al. Constant modulus algorithm for co-channel signal separation in non-Gaussian impulsive noise environments[J]. Wireless Personal Communications, 2010, 54: 591-604.

[12] 刘剑锋, 于宏毅, 杜剑平, 等. 基于领域自适应的动态噪声辐射源个体识别[J]. 信号处理, 2021, 37(6): 1000-1007.
Liu J F, Yu H Y, Du J P, et al. Individual identification of dynamic noise radiation source based on domain adaptation[J]. Journal of Signal Processing, 2021, 37(6): 1000-1007.

[13] 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.
Guo Y C, Yao W Q. Modulation signal classification and recognition algorithm based on signal-to-noise ratio classification network[J]. Journal of Electronics & Information Technology,

- 2022, 44(10): 3507-3515.
- [14] Xu L, Fu X, Wang Y, et al. Enhanced few-shot specific emitter identification via phase shift prediction and decoupling[C]// Proceedings of the IEEE Transactions on Cognitive Communications and Networking. Piscataway: IEEE Press, 2025:145-155.
- [15] Zhang Y, Zhang Q, Zhao H, et al. Multisource heterogeneous specific emitter identification using attention mechanism-based rff fusion method[J]. IEEE Transactions on Information Forensics and Security, 2024, 19: 2639-2650.
- [16] Zhang F, Luo C, Xu J, et al. An autoencoder-based I/Q channel interaction enhancement method for automatic modulation recognition[J]. IEEE Transactions on Vehicular Technology, 2023, 72(7): 9620-9625
- [17] 王子恒, 张徐, 高硕, 等. 一种复数域轻量化知识蒸馏驱动的调制识别模型[J]. 电信科学, 2025, 41(8): 163-175.
Wang Z H, Zhang X, Gao S, et al. A complex domain lightweight knowledge distillation driven modulation recognition model[J]. Telecommunications Science, 2025, 41(8): 163-175.
- [18] Shen G, Zhang J, Marshall A, et al. Toward length-versatile and noise-robust radio frequency fingerprint identification[J]. IEEE Transactions on Information Forensics and Security, 2023, 18: 2355-2367.
- [19] O'Shea T J, Corgan J, Clancy T C. Convolutional radio modulation recognition networks[C]//Proceedings of the Engineering Applications of Neural Networks: 17th International Conference. Aberdeen, UK: Springer, 2016: 213-226.
- [20] Sathyanarayanan V, Gerstoft P, El Gamal A. Data centric approach to modulation classification[C]//Proceedings of the 2023 15th International Conference on Communication Systems & Networks (COMSNETS). Piscataway: IEEE Press, 2023: 340-344.
- [21] Liu C, Cai Z, Zhang B. Automatic modulation classification based on complex-valued convolutional neural network and semi-supervised learning[C]//Proceedings of the 2023 IEEE 23rd International Conference on Communication Technology (ICCT). Piscataway: IEEE Press, 2023: 241-246.
- [22] Ding L, Wang S, Wang F, et al. Specific emitter identification via convolutional neural networks[J]. IEEE Communications Letters, 2018, 22(12): 2591-2594.
- [23] Ding W, Guo X, Wang G. Radar-based human activity recognition using hybrid neural network model with multidomain fusion[J]. IEEE Transactions on Aerospace and Electronic Systems, 2021, 57(5): 2889-2898.
- [24] 王天池, 俞璐, 赫德军. 基于对抗的一致性正则半监督辐射源个体识别方法[J]. 计算机测量与控制, 2023, 31(2): 204-209.
Wang T C, Yu L, He D J. Adversarial-based consistency regularization semi-supervised specific emitter identification method[J]. Computer Measurement & Control, 2023, 31(2): 204-209.
- [25] Cheng R, Chen Q, Huang M. Automatic modulation recognition using deep CVCNN-LSTM architecture[J]. Alexandria En-

gineering Journal, 2024, 104: 162-170.

- [26] Zhang F, Luo C, Xu J, et al. An autoencoder-based I/Q channel interaction enhancement method for automatic modulation recognition[J]. IEEE Transactions on Vehicular Technology, 2023, 72(7): 9620-9625.
- [27] Liu C, Fu X, Wang Y, et al. Overcoming data limitations: a few-shot specific emitter identification method using self-supervised learning and adversarial augmentation[J]. IEEE Transactions on Information Forensics and Security, 2024, 19: 500-513.

[作者简介]



赵少坤 (2001-), 男, 成都理工大学机电工程学院硕士生, 主要研究方向为辐射源个体识别。



贾勇 (1985-), 男, 博士, 成都理工大学机电工程学院教授、硕士生导师, 主要研究方向为智能信号处理、电磁感知。



张伟 (1985-), 男, 博士, 电子科技大学通信与信息工程学院高级工程师, 主要研究方向为电磁感知、电磁大数据。



姚光乐 (1985-), 男, 博士, 成都理工大学机电工程学院副教授、硕士生导师, 主要研究方向为电磁感知、计算机视觉。



张建 (2001-), 男, 成都理工大学机电工程学院硕士生, 主要研究方向为辐射源个体识别。