

基于BYOL和对比聚类的通信信号无监督调制识别方法

李道全, 姜云聪, 于全林, 贾魏飞, 胡兆旭

(青岛理工大学信息与控制工程学院, 青岛 266520)

摘要: 针对现有方法在实际无线电环境中过度依赖标注数据, 难以准确识别未知调制类型的问题, 本文提出一种基于自举式潜在特征法(Bootstrap your own latent, BYOL)自监督表征学习与对比聚类机制的无监督通信信号调制识别方法。本文方法无需任何人工标注, 首先利用BYOL框架, 通过双分支结构分别处理同一信号的不同子片段, 以自监督方式学习信号数据的内在稳定特征。其次, 引入实例级与聚类级对比学习模块, 前者增强同一信号不同增强视图的特征一致性, 后者提高特征空间不同调制类型的区分性, 从而实现未知调制类型的高精度盲分类。实验在RadioML2018.01A数据集上进行验证, 各项聚类评价指标相比现有算法均提升10%以上。此外, 通过消融实验进一步证实BYOL模块与对比聚类机制对模型性能提升的关键作用。混淆矩阵分析表明, 在10 dB下该方法对带载波双边带调幅(Amplitude modulation double-sideband with carrier, AM-DSB-WC)、频率调制(Frequency modulation, FM)、高斯最小频移键控(Gaussian minimum shift keying, GMSK)等典型调制类型识别准确率接近理想值, 对其他较难区分的类型也表现出较强的抗混淆能力与鲁棒性, 体现了良好的泛化性能。

关键词: 无监督学习; 调制识别; 对比聚类; 自监督学习

中图分类号: TN911.7 **文献标志码:** A

引用格式: 李道全, 姜云聪, 于全林, 等. 基于BYOL和对比聚类的通信信号无监督调制识别方法[J]. 数据采集与处理, 2026, 41(3): 882-895. LI Daoquan, JIANG Yuncong, YU Quanlin, et al. An unsupervised modulation recognition method for communication signals based on BYOL and contrastive clustering[J]. Journal of Data Acquisition and Processing, 2026, 41(3): 882-895.

引言

调制识别技术最早源于军事通信领域的需求。1969年, Weaver等^[1]发表了关于调制类型自动分类的早期研究, 首次将模式识别方法引入调制识别问题, 通常被认为是自动调制识别(Automatic modulation recognition, AMR)研究的开端之一。此后, AMR技术不断发展, 目前主流的自动调制识别方法主要分为基于特征(Feature-based, FB)的对比识别和基于似然(Likelihood-based, LB)的检验识别两类。近年来兴起的深度学习(Deep learning, DL)方法, 则不需要信号的先验信息或人工设计特征。

基于似然的自动调制识别方法本质上属于多复合假设检验(Composite hypothesis testing)问题。其识别过程可简化为: 接收信号后, 通过分析计算其似然值, 再由似然值获得检验统计量, 最后依据判决准则实现调制分类。1990年, Polydoros和Kim^[2]将接收信号中的未知量视为随机变量并取平均值, 应用于二进制相移键控(Binary phase shift keying, BPSK)和正交相移键控(Quadrature phase shift keying, QPSK)的调制识别, 使分类准确率得到显著提升。1998年, Boiteau等^[3]首次提出广义似然比检验(Generalized likelihood ratio test, GLRT)理论。基于似然的方法可在贝叶斯代价最小化的准则下有效

提高识别准确率,但其最优解通常受限于计算复杂度,因此实际中往往选择次优解以降低复杂度。

基于特征的对比识别方法理论基础为经典模式识别。由于不同调制信号参数差异较大,因此可以利用这些差异设计特征实现信号的调制识别。常用的特征包括高阶累积量^[4-5]、小波变换、循环谱^[6]、星座图以及瞬时特征等。

近年来,基于深度学习的调制识别方法因其端到端的学习特性,仅需对信号进行简单预处理即可自动完成特征提取与模式识别,因此受到广泛关注。基于卷积神经网络(Convolutional neural network, CNN)的调制识别方法最早由O'Shea等^[7]提出,并首次在其公开的RadioML2016.10A数据集上进行训练^[8],取得了较高的识别准确率。文献[9]提出一种低计算复杂度的星座图降维算法,将信号星座图转换为25像素×25像素的图像,使用深度信念网络(Deep belief network, DBN)^[10]进行训练,有效降低了训练过程中的计算成本。为充分利用像素密度与颜色特征,文献[11]提出了一种称为“轮廓恒星图”的星座图表示方法,并采用生成对抗网络(Generative adversarial network, GAN)进行训练。文献[12]针对星座图的数据增强方法进行研究,通过增强图像对比度突出信号样本密集区域的特征。为增强深度学习算法的抗噪性能,文献[13]引入了基于二阶与四阶矩估计器的多标签深度学习方法,以解决信噪比(Signal-to-noise ratio, SNR)变化带来的识别问题。文献[14]为提高网络的调制识别精度,在训练中采用掩码丢弃星座图中显著的噪点及误差较大的星座点。文献[15]通过剪枝优化深度神经网络参数数量,在可接受的精度损失范围内有效提升了模型的推理速度。随后,研究人员采用循环神经网络(Recurrent neural network, RNN)进行调制类型识别,发现其性能优于单独使用CNN的方法^[16]。在此基础上,研究人员提出了融合CNN与RNN的卷积长短期深度神经网络(Convolutional long short-term deep neural network, CLDNN)网络^[17],核心思想是利用CNN的特征提取能力降低输入长短期记忆网络(Long short-term memory, LSTM)的数据维度,以提升网络性能与收敛速度。Liao等^[18]随后提出序列卷积循环神经网络(Sequential convolutional recurrent neural network, SCRNN)网络,证明在LSTM前增加CNN层能有效提高网络的收敛速度。文献[19]提出一种基于深度神经网络的相位变换算法,通过估计信号相位参数进行数据预处理,并构建卷积双向长短期记忆(Convolutional bidirectional long short-term memory, CNN-BiLSTM)网络。与传统CNN相比,调制识别准确率提升了12%。文献[20]考虑并消除了正交频分复(Orthogonal frequency division multiplexing, OFDM)通信系统中载波相位偏移的有害影响,达到了较高的调制识别准确率。文献[21]对多种信号特征进行融合,对多子序列的结果进行组合,得到了更好的调制识别准确率。

尽管深度学习在充足标记数据条件下表现优异,但在实际的认知无线电应用中,很难获得大规模的标注数据,并且难以预先覆盖所有可能出现的调制类型。因此,研究者开始探索无监督及自监督的调制识别方法,以未标记数据进行模型训练或聚类,从而实现对未知信号的自动分类^[22]。文献[23]提出一种基于对比学习的自监督调制识别框架自监督对比学习自动调制分类(Self-supervised contrastive learning for automatic modulation classification, SSCL-AMC)。该方法通过对接收信号进行时间裁剪、幅度缩放等数据增强生成“正样本对”,并利用对比损失预训练卷积神经网络,使得同一信号的不同增强表示相互靠近,不同信号的表示相互远离。随后,仅需少量标注数据对网络进行微调,即可有效完成调制分类任务。此外,一些研究尝试直接利用未标记数据进行聚类分类。一种典型方法是首先训练特征提取模型(如自编码器或深度网络),将信号映射到低维空间,再对特征向量执行K-means或基于密度的含噪空间聚类(Density-based spatial clustering of applications with noise, DBSCAN)等聚类算法,以实现信号按调制类型自动分组。由于不同调制信号在特征空间中通常形成可分离的簇,因此这种方法具备无需人工标签实现调制分类的潜力。例如,Li等^[24]采用GAN进行半监督训练,GAN的判别器既进

行已知调制类型的监督分类,又通过对抗训练学习区分已知与未知信号的特征表示。实验表明,在未标记样本比例较高的情况下,相比单纯的监督CNN,引入GAN的半监督模型能取得更高的分类准确率。邵凯等^[25]结合GAN生成模型与卷积网络判别器,即使在部分调制类型缺乏标签的情况下,也能准确识别多种调制信号。还有研究利用稀疏编码与逐层自编码预训练初始化CNN网络,再对信号进行聚类,从而获得比随机初始化更高的聚类纯度^[26]。尽管上述方法尚未完全摆脱对部分标注的依赖,但已在减少标注数据需求方面迈出了重要一步。

针对现有方法仍依赖部分标注数据的问题,结合目前已有的研究内容,本文提出了一种基于自举式潜在特征法(Bootstrap your own latent, BYOL)的无监督对比聚类通信信号调制识别方法,在不需要类别标签的前提下端到端地进行调制类型盲聚类。与现有无监督方法相比,本文方法在RadioML2018.01A公开数据集上实现了更高的聚类精度,具体实验结果对比见2.2节。

1 模型框架

基于BYOL的无监督对比聚类通信信号调制识别方法框架的结构为双分支自监督对比网络^[27],并在其编码器后额外增加两个分支,用于实现对比聚类^[28]。首先,将完整的同相(In-phase, I)/正交(Quadrature, Q)信号切分为若干子片段。由于BYOL架构无需负样本对,因此从同一信号子片段中随机抽取两个片段作为正样本对,分别输入在线网络与目标网络进行特征表示,并通过最小化二者的相似度损失,学习信号的隐含特征分布。编码器后增加两个输出分支:一个分支用于进一步降维编码特征,并采用实例级对比损失优化每个样本的实例特征表示;另一个分支则将编码器输出的特征压缩至与类别数量相同的维度,并通过聚类级对比学习损失约束整体样本的类别分布特征。通过上述框架的端到端学习,可以在无标签情况下实现对不同调制类别的高精度盲聚类。

1.1 数据集格式

在认知无线电和无线通信系统中,由于信道条件复杂,接收器的调制类型多样且未知,接收器必须在解调和解码过程之前进行调制识别。因此,调制识别在整个接收过程中起着至关重要的作用。在发射端,经过信源编码、加密和信道编码后,模拟或数字信号被传输到调制器。在调制器中,前一阶段生成的信息比特被映射为各种调制符号,然后传递到射频处理模块。调制后的信号 $s(t)$ 通过天线发送并在信道中传播,在此过程中可能会遇到噪声和其他失真。在接收端,接收天线捕获的信号首先通过射频处理转换为基带信号。随后,使用自动调制识别模块对基带信号的调制类型进行分类,接着进行解调和解码过程。接收到的信号 $r(t)$ 可以表示为

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

式中: $s(t)$ 表示在时间 t 的调制信号, $c(t)$ 表示无线信道的冲激响应, $n(t)$ 是零均值的加性高斯白噪声(Additive white Gaussian noise, AWGN)。传输信号 $s(t)$ 的表达式根据调制方案的不同而有所变化。当信号采用幅移键控(Amplitude shift keying, ASK)、频移键控(Frequency shift keying, FSK)或相移键控(Phase shift keying, PSK)进行调制时, $s(t)$ 的形式表示为

$$s(t) = [A_m \sum a_n g(t - nT)] \cdot \cos[2\pi(f_c + f_m)t + \phi_0 + \phi_m] \quad (2)$$

式中: A_m 为调制幅度, a_n 为符号序列, $g(\cdot)$ 为信号脉冲, T 为符号周期, f_m 为调制频率, f_c 为载波频率,参数 ϕ_0 表示初始相位, ϕ_m 表示调制相位。此外,正交幅度调制(Quadrature amplitude modulation, QAM)不同于前面提到的调制方案。在QAM中,存在两个正交载波,并且信号由 a_n 和 b_n 共同调制。此时传输信号 $s(t)$ 可表示如下

$$s(t) = \left[A_m \sum_n a_n g(t - nT) \right] \cos(2\pi f_c t + \phi_0) + \left[A_m \sum_n b_n g(t - nT) \right] \sin(2\pi f_c t + \phi_0) \quad (3)$$

在接收端, $r(t)$ 以 I/Q 格式表示, 并由模数转换器 (Analog-to-digital, AD) 以 $f_s = 1/T_s$ 的速率采样 k 次。 $r(t)$ 的实部和虚部分别对应于 I/Q 分量。更具体地说, $r(t)$ 还可以表示为

$$r(t) = \alpha(t) e^{j(2\pi f_0 t + \theta_0)} s(t) + n(t) \quad (4)$$

式中: $\alpha(t)$ 表示瑞利衰落因子, 而 f_0 和 θ_0 分别表示由不同本地振荡器和多普勒效应引入的频率和相位偏移。为了便于数字处理, 接收机往往将连续的时间信号离散化, 并将复值信号 $r(t)$ 拆分为实部 (I 路, 用 R 表示) 与虚部 (Q 路, 用 I 表示)

$$r_I[t] = R\{r[t]\}, r_Q[t] = I\{r[t]\} \quad (5)$$

将这两个分量合并, 并且分成若干长度相等的子片段, 即可得到本文所需要的数据集

$$y = \left[\begin{array}{c} \left[R\{r[1]\}, R\{r[2]\}, \dots, R\{r[m]\} \right], \left[R\{r[m+1]\}, R\{r[m+2]\}, \dots, R\{r[2m]\} \right], \dots, \\ \left[I\{r[1]\}, I\{r[2]\}, \dots, I\{r[m]\} \right], \left[I\{r[m+1]\}, I\{r[m+2]\}, \dots, I\{r[2m]\} \right], \dots, \\ \left[R\{r[L-m+1]\}, R\{r[L-m+2]\}, \dots, R\{r[L]\} \right], \\ \left[I\{r[L-m+1]\}, I\{r[L-m+2]\}, \dots, I\{r[L]\} \right] \end{array} \right] \quad (6)$$

式中: m 为子片段的长度, L 为完整信号的长度, 结尾不足一个子片段的剩余采样点做丢弃处理。在本文中, 将 1 024 点的 I/Q 信号按顺序切分为 8 个不重叠的 128 点子片段 (即从 1~128、129~256...897~1 024 点切分), 结尾不足 128 点的片段丢弃。

1.2 模型结构

模型整体结构如图 1 所示, 使用 3 层多层感知机 (Multi-layer perceptron, MLP) 作为投影器与预测器。BYOL 是一种无需负样本对的对比学习框架。在对比学习中, 如何有效构造正负样本对始终是核心挑战之一。由于同一长信号的不同子片段天然属于正样本对, 本研究采用 BYOL 框架以充分利用这一特性: 对同一信号的不同子片段 y_a, y_b , 分别输入在线网络 (Online network) 和目标网络 (Target network), 从而获得两种视图的表示。

$$z_{ol} = q_\theta(g_\theta(f_\theta(y_a))) \quad (7)$$

$$z_{tar} = g_\xi(f_\xi(y_b)) \quad (8)$$

式中: f_θ, g_θ 和 q_θ 分别表示在线网络的编码器、投影器与预测器; g_ξ 和 f_ξ 分别表示目标网络的编码器和投影器。在线与目标网络架构相同但权重不同。目标网络提供了在线网络的回归目标, 其参数 ξ 是在线网络参数 θ 的指数移动平均值 (Exponential moving average, EMA)

$$\xi \leftarrow \tau \xi + (1 - \tau) \theta \quad \tau \in [0, 1] \quad (9)$$

式中: τ 为 EMA 系数, 通常设为接近 1 的值, 保证目标网络的更新较为平稳, “ \leftarrow ” 表左侧参数更新为右侧表达式计算结果。

在得到 z_{ol} 和 z_{tar} 之后, 对其进行 ℓ_2 正则化, 得到

$$\overline{z}_{ol} \triangleq z_{ol} / \|z_{ol}\|_2 \quad (10)$$

$$\overline{z}_{tar} \triangleq z_{tar} / \|z_{tar}\|_2 \quad (11)$$

其中, 预测器仅应用于在线网络, 使在线与目标网络形成非对称结构。二范数正则化确保特征向量处于单位超球面, 使相似度计算更可靠, 提升对比学习的稳定性与特征区分性。最后, 定义标准化预测与目标映射之间的均方根误差

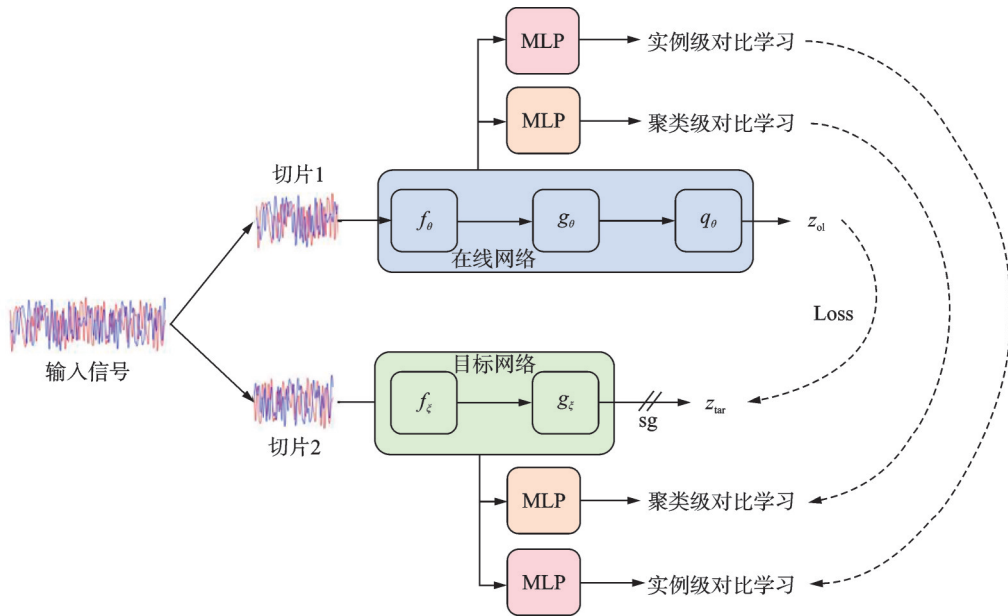


图1 基于BYOL的无监督对比聚类通信信号调制识别模型整体框架

Fig.1 Overall framework of unsupervised communication signal modulation identification method based on BYOL self-supervised representation learning and comparison clustering

$$\mathcal{L}_{\theta, \xi} \triangleq \|\bar{\mathbf{z}}_{ol} - \bar{\mathbf{z}}_{tar}\|_2^2 = 2 - 2 \cdot \frac{\langle \bar{\mathbf{z}}_{ol}, \bar{\mathbf{z}}_{tar} \rangle}{\|\bar{\mathbf{z}}_{ol}\|_2 \cdot \|\bar{\mathbf{z}}_{tar}\|_2} \quad (12)$$

该损失的目标是使在线网络的预测向量 \mathbf{z}_{ol} 尽量逼近目标网络的投影向量 \mathbf{z}_{tar} 。随后交换两个分支的输入,即将 y_a 输入目标网络,将 y_b 输入在线网络,再次计算均方根误差以得到对称损失 $\tilde{\mathcal{L}}_{\theta, \xi}$ 。在每个训练步骤中,通过梯度下降根据 $\mathcal{L}_{\theta, \xi}^{BYOL} = \mathcal{L}_{\theta, \xi} + \tilde{\mathcal{L}}_{\theta, \xi}$ 优化 θ , 但不更新 ξ , 完成BYOL的整体优化

$$\theta \leftarrow \text{optimizer}(\theta, \nabla_{\theta} \mathcal{L}_{\theta, \xi}^{BYOL}, \eta) \quad (13)$$

$$\xi \leftarrow \tau \xi + (1 - \tau) \theta \quad (14)$$

本方法中,采用1D-ResNet18作为编码器,使用MLP作为投影器与预测器;其中编码器、投影器与预测器的输出维度均为128,具体结构如图2所示。

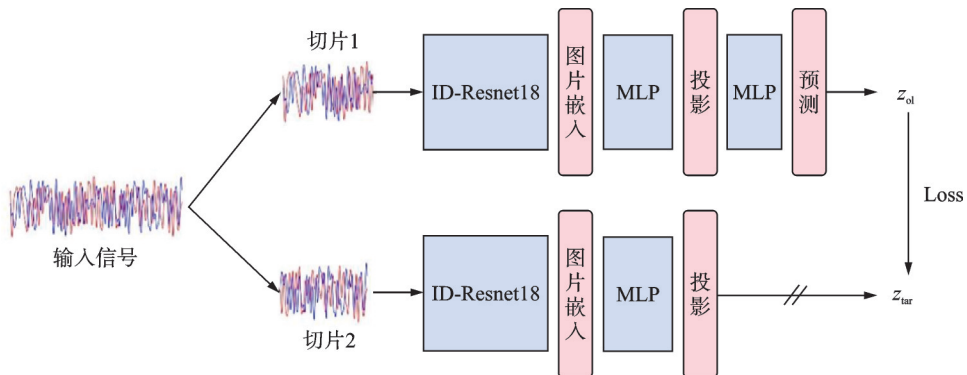


图2 BYOL的结构

Fig.2 Structure of BYOL

在此框架基础上,引入对比聚类模块以实现端到端的无监督调制识别。具体而言,在在线网络和目标网络的编码器后额外增加两个分支:实例级对比分支与聚类级对比分支(如图3所示)。该方法将表示学习分为两个维度的联合对比学习。

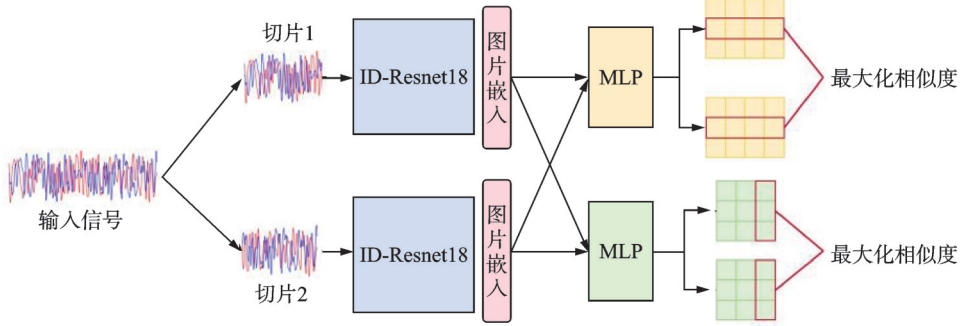


图3 对比聚类模块的结构

Fig.3 Structure of contrastive clustering

实例级对比学习(Instance-level contrastive learning):目标在于学习高质量的实例表示,使同一信号的不同子片段在特征空间中互相靠近,不同信号的子片段在特征空间中互相远离。在获取两个分支的编码特征 $f_{\theta}(y_a)$ 和 $f_{\xi}(y_b)$ 之后,通过全连接层对其进行特征投影,得到实例级特征表示 I_a 和 I_b ;随后,利用实例级对比损失公式对其进行约束

$$\mathcal{L}_{\text{ins}} = - \sum \log_{10} \frac{\exp(\text{sim}(I_a, I_b)/\tau)}{\sum_{j=1, b \neq a}^N \exp(\text{sim}(I_a, I_j)/\tau)} \quad (15)$$

式中: I_j 表示同批数据中与 I_a 属于不同信号子片段的特征, $\text{sim}(\cdot)$ 表示相似度函数, τ 表示温度系数。与BYOL框架相同,将 I_a 与 I_b 交换后再次计算损失,以得到总的实例级损失 $\mathcal{L}_1 = \mathcal{L}_{\text{ins}} + \tilde{\mathcal{L}}_{\text{ins}}$,其中 $\tilde{\mathcal{L}}_{\text{ins}}$ 为 \mathcal{L}_{ins} 的对称损失。

聚类级对比学习(Cluster-level contrastive learning):目标在于区分不同类别的簇表示,使同一簇(类别)内的实例彼此靠近,而不同簇间的距离拉远。获取两个分支的编码特征 $f_{\theta}(y_a)$ 和 $f_{\xi}(y_b)$ 后,通过全连接层计算每个实例的类别概率分布,得到聚类级特征表示 C_a 和 C_b ;随后计算聚类级对比损失

$$\mathcal{L}_{\text{clus}}^i = - \log_{10} \frac{\exp(\text{sim}(C_i^a, C_i^b)/\tau_c)}{\sum_{j=1}^M [\exp(\text{sim}(C_i^a, C_j^a)/\tau_c) + \exp(\text{sim}(C_i^a, C_j^b)/\tau_c)]} \quad (16)$$

式中: C_i^a 和 C_i^b 分别为 C_a 和 C_b 的第 i 个类别的分量; C_j^a 和 C_j^b 则为 C_a 和 C_b 的第 j 个类别的分量。与实例级对比学习相同,交换 C_a 和 C_b 后计算对称损失 $\tilde{\mathcal{L}}_{\text{clus}}^i$,并最终得到整体损失

$$\mathcal{L}_C = \frac{1}{2M} \sum_{i=1}^M (\mathcal{L}_{\text{clus}}^i + \tilde{\mathcal{L}}_{\text{clus}}^i) - H(Y) \quad (17)$$

式中 $H(Y)$ 为分配概率的熵,有助于避免大多数实例被分配给同一个类簇。

通过联合优化这两个维度的特征表示,可同时保留实例差异与簇间差异。最终损失函数由上述两个损失函数组合而成,即

$$\mathcal{L}_{\text{CC}} = \mathcal{L}_1 + \mathcal{L}_C \quad (18)$$

通过上述两个模块的融合,可以得到整个框架的损失函数

$$\mathcal{L}_{\text{total}} = \mathcal{L}_{\theta, \xi}^{\text{BYOL}} + \lambda \mathcal{L}_{\text{CC}} \quad (19)$$

式中 λ 为权衡系数。从而在无标签的条件下实现对不同调制类别的盲聚类与识别。

2 实验结果与分析

2.1 数据集以及实验参数设定

使用RadioML2018.01A^[29]无线电信号数据集对所提方法进行评估。该数据集包含2 555 904个无线电信号样本,涵盖24种调制类型(如二进制相移键控(Binary phase shift keying, BPSK)、QPSK、8PSK、16PSK、64幅相移键控(Amplitude and phase shift keying, APSK)、32APSK、16QAM、32QAM、64QAM和偏移四相相移键控(Offset quadrature phase shift keying, OQPSK)等),SNR范围为-20 dB~30 dB。每个样本含1 024个IQ双通道数据点,提供 $2 \times 1 024$ 的标准输入规模;具体参数见表1。鉴于一次性处理所有调制类型难度较高,本研究选取具有代表性的8种调制方式(开关键控(On-off keying, OOK)、BPSK、16APSK、16QAM、带载波双边带调幅(Amplitude modulation double-sideband with carrier, AM-DSB-WC)、频率调制(Frequency modulation, FM)、高斯最小频移键控(Gaussian minimum shift keying, GMSK)、OQPSK)进行实验。

表1 RML2018.01A 配置信息

Table 1 RML2018.01A configuration information

RML2018.01A	具体信息
调制方式	24类(OOK, 4ASK, 8ASK, BPSK, QPSK, 8PSK, 16PSK, 32PSK, 16APSK, 32APSK, 64APSK, 128APSK, 16QAM, 32QAM, 64QAM, 128QAM, 256QAM, 带载波单边带调幅(Amplitude modulation single-sideband with carrier, AM-SSB-WC), 抑制载波单边带调幅(Amplitude modulation single-sideband suppressed carrier, AM-SSB-SC), 抑制载波双边带调幅(Amplitude modulation double-sideband suppressed carrier, AM-DSB-SC), AM-DSB-WC, FM, GMSK, OQPSK)
数据量	2 555 904
数据格式	(1 024, 2)
信噪比范围	-20~30 dB, 步长 2 dB
噪声	AWGN
数据来源	GNU Radio仿真

本实验采用无监督框架,无需区分训练集与验证集。训练过程批次大小为256,优化器为Adam,初始学习率0.001,训练轮数设为300个Epoch,信号子片段长度为128。所有网络基于PyTorch实现,实验平台为Intel(R) Core(TM) i9-14900K CPU、64 GB内存和GeForce RTX 3090 24 GB显存。性能评估采用5种常用聚类指标:归一化互信息(Normalized mutual information, NMI)、调整兰德系数(Adjusted Rand index, ARI)、 F -measure(F)、聚类准确率(Clustering accuracy, ACC)与聚类纯度(Purity, PUR)。其中NMI、 F 、ACC和PUR的取值范围为 $[0, 1]$,ARI取值范围为 $[-1, 1]$,数值越大表明聚类性能越优。

2.2 实验结果分析

聚类完成后,采用“多数投票法”的标签映射算法将聚类簇映射到真实标签:对于每个聚类簇,统计其包含的真实样本中占比最高的调制类型,作为该簇的映射标签。表2展示了本文方法与其他方法的性能比较,包括K-means^[30]、基于密度的含噪空间聚类(Density-based spatial clustering of applications with noise, DBSCAN)^[31]、跨视图对比学习(Cross-view contrastive learning, CVCL)^[32]以及DeepCluster^[33],所有对比方法均统一采用1D-ResNet18特征提取器与原始信号输入。

根据表2中实验结果可见,所提模型在各项聚类指标上均明显优于传统聚类方法(如K-means、DBSCAN)及现有先进深度聚类方法(如CVCL、DeepCluster),更直观的表现如图4所示。具体而言,在NMI、ARI、 F 、ACC和PUR这5项聚类指标上,所提模型分别达到0.376 5、0.351 6、0.406 2、0.482 6和0.461 4,整体表现显著超越其他对比方法。与传统聚类方法相比(如经典K-means),所提方法在NMI上提升约32.84%,在ACC上提升约26.32%,展现出深度表征学习在复杂数据特征挖掘方面的优势。此外,相较DBSCAN,所提模型在ARI指标上实现逾32%的绝对提升,进一步验证了其在挖掘数据内在结构方面的有效性。与此同时,相较于现有深度聚类方法(如DeepCluster),所提模型在NMI上提升约20.83%,ACC提升约18.82%。其中,DeepCluster作为一种基于深度特征重构的聚类方法,所提模型引入BYOL自监督学习与对比聚类策略,解决了特征空间内类内不紧密、类间边界不清晰的问题,从而更准确地捕捉数据的内在聚类结构。这种优势亦反映在 F 与PUR指标上: F 从DeepCluster的0.293 0显著提升至0.406 2,PUR从0.296 7提升至0.461 4,表明所提方法对聚类结果的可靠性与稳定性均有提升。

从图5所示混淆矩阵可见,所提模型在具体类别上的识别表现更为出色。其中在SNR=10 dB环境下,AM-DSB-WC、FM、GMSK的识别准确率分别达0.98、0.97、0.96,体现出模型对典型调制方式的优异区分能力。从图5的混淆矩阵可以深入分析模型的判决行为。在10 dB SNR下,AM-DSB-WC、FM和GMSK的识别率极高,这是因为模拟调制信号与数字调制信号在时域包络和频域特征上差异显著,BYOL模块通过对比学习成功捕捉了这些本质差异。然而,主要的混淆集中在QAM与APSK类调制信号之间,以及部分高阶PSK信号。例如,16QAM与16APSK均属于幅度与相位联合变化的高阶调制。在未知载波相位偏移、频偏、幅度缩放以及衰落与噪声共同作用下,星座点云会出现旋转、缩放与

表2 不同聚类方法的性能对比

Table 2 Performance comparison of different clustering methods

方法	NMI	ARI	F	ACC	PUR
K-means	0.048 1	0.027 4	0.219 4	0.219 4	0.221 1
DBSCAN	0.144 3	0.026 6	0.077 1	0.220 0	0.220 0
CVCL	0.116 7	0.110 7	0.256 9	0.280 0	0.285 1
DeepCluster	0.168 2	0.142 1	0.293 0	0.294 4	0.296 7
Ours	0.376 5	0.351 6	0.406 2	0.482 6	0.461 4

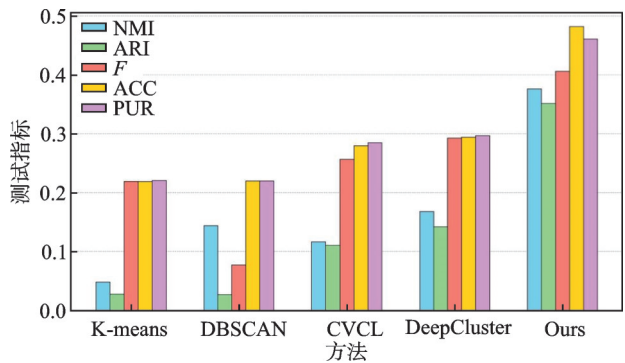


图4 不同方法的测试性能

Fig.4 Test performance of different methods

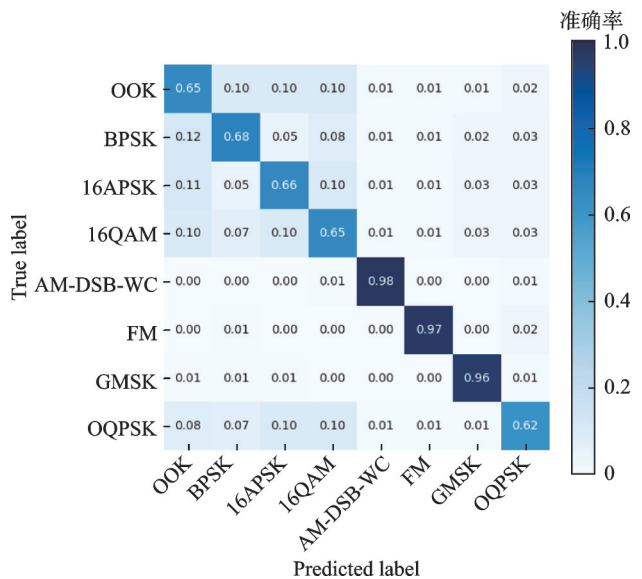


图5 10 dB下的混淆矩阵

Fig.5 Confusion matrix at 10 dB

扩散,使得两类信号在部分统计特征空间中的分布更为接近,从而增加区分难度。尽管如此,得益于对比聚类机制对类间距离的拉伸作用,本文方法相比传统K-means在区分这些高阶调制信号时仍保持了较高的纯度,说明模型不仅仅依赖瞬时幅度特征,还学习到了信号潜在的时序相关性。不同模型的聚类效果图如图6所示。

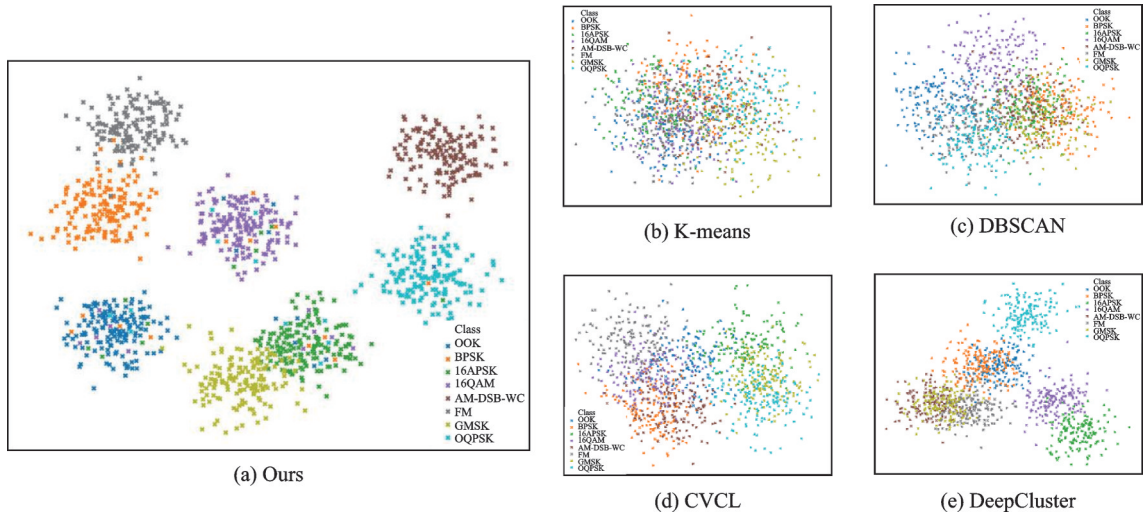


图6 SNR=10 dB下不同方法下的聚类效果示意图

Fig.6 Schematic representation of clustering effects of different methods at SNR=10 dB

为进一步验证本文所提BYOL表征学习与对比聚类联合框架的有效性,对比了模型在仅采用BYOL表征阶段和完整聚类优化后的特征空间分布差异,结果如图7所示。其中,图7(a)表示仅通过BYOL编码器获得的特征分布。可以看到,在未引入对比聚类机制时,各类信号在特征空间中呈现较明显的相互交叉和重叠,类间界限模糊,特征聚合性较弱,反映出单纯自监督特征表征难以直接实现高质量的信号区分。图7(b)为在SNR=10 dB环境下经过完整的BYOL和对比聚类联合训练后所获得的聚类效果。对比可见,各调制类型的聚类簇明显分离,类间边界清晰且类内紧凑性明显提高,NMI、ACC等指标也显著提升,验证了联合训练框架对特征聚类性能的重要作用。

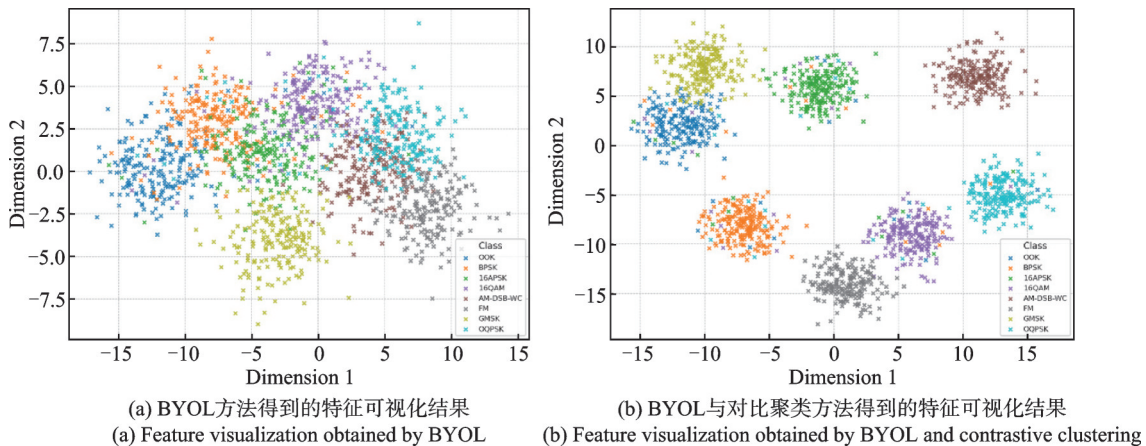


图7 BYOL特征空间与聚类结果的联合可视化

Fig.7 Joint visualization of BYOL feature space and clustering results

综上所述,实验结果证实所提模型在提高聚类精度、增强类别区分度及挖掘复杂信号内部特征结构方面的有效性与先进性,表明该方法在复杂场景下更能胜任无监督信号聚类任务的需求;与此同时,两阶段特征空间可视化结果充分说明了所提方法中BYOL自监督模块与对比聚类模块之间的相互协同关系,进一步佐证了本文方法在盲聚类调制识别任务上的有效性。

2.3 计算复杂度与运行效率分析

为了全面评估算法的性能,除了聚类精度外,本文还对比了DeepCluster与本文方法(Ours)的模型参数量以及单轮训练耗时。虽然本文方法引入了双分支结构,但在推理阶段仅需保留Online网络的编码器部分,因此推理时间并未显著增加。与DeepCluster相比,本文方法省去了每轮迭代中对全量数据进行伪标签K-means聚类的过程,实现了端到端的训练。

从表3中可以看出,尽管本文方法由于双分支结构导致参数量略有增加,且训练耗时略长,但并未产生数量级的差异。考虑到本文方法相较于DeepCluster在NMI和ACC指标上分别提升了20.8%和18.8%,这种计算成本的增加是可以接受的。这证明了所提架构在保持合理计算开销的同时,显著提升了识别性能,验证了其在实际部署中的可行性。

表3 计算复杂度与运行效率对比

Table 3 Comparison of computational complexity and runtime efficiency

方法	参数量/ 10^6	训练耗时/(s \cdot epoch $^{-1}$)	推理耗时/(ms \cdot batch $^{-1}$)
DeepCluster	11.2	45.2	12.5
Ours	12.8	52.6	13.1

2.4 消融实验

为了证明本文提出的不同组件的有效性,本节设计了不同的消融实验,其中包括:不使用BYOL架构进行自监督训练,直接进行对比聚类,以及不使用对比聚类方法,而是在BYOL训练完成后使用K-means对其编码器特征进行聚类。

为验证所提方法中各组件的有效性,本节设置多组消融实验:(1)在无BYOL架构的情况下直接进行对比聚类;(2)在完成BYOL训练后,不采用对比聚类,而改用K-means对编码器特征聚类。具体结果见表4。由表4可见,在移除BYOL模块后,各项指标均明显下降:NMI从0.376 5降至0.257 3,ACC从0.482 6降至0.351 7, F 同样显著降低。表明BYOL模块能够在训练过程中提升特征表征的稳定性与一致性,从而更准确地捕捉数据的潜在聚类结构。此外,进一步移除对比聚类模块后,模型的聚类性能再次大幅下降:NMI、ACC分别降至0.181 6、0.253 7,PUR也降至0.270 4,明显低于完整模型的0.461 4。由此可见,对比聚类机制可有效增强类间区分度与类内紧密性,在提升模型整体性能方面具有关键作用。

表4 消融实验结果

Table 4 Results of ablation experiments

模块	NMI	ARI	F	ACC	PUR
不使用BYOL	0.257 3	0.272 6	0.326 7	0.351 7	0.343 8
不使用对比聚类	0.181 6	0.173 9	0.232 6	0.253 7	0.270 4

此外,针对式(19)中的损失权重 λ ,在保持其余超参数不变的情况下,分别将 λ 设为 0 、 1×10^{-2} 、 5×10^{-2} 、 1×10^{-1} 、 5×10^{-1} 和 1 ,并在数据集上完整训练与测试。实验结果见表5:当 λ 位于 $10^{-2} \sim 10^{-1}$ 区间时,模型所有聚类指标均处于高位且波动极小,其中 $\lambda = 5 \times 10^{-2}$ 时综合性能最佳,NMI、ARI、 F 、ACC和

PUR 分别达到 0.376 5、0.351 6、0.406 2、0.482 6 和 0.461 4；与 $\lambda=0$ 相比，ACC 提升约 9%，NMI 提升约 6.5%，验证了对比聚类约束对类间可分性的关键作用。将 λ 设为 0 等同于去除对比聚类项，此时模型退化为纯 BYOL，自监督特征仅保证实例级一致性而缺少簇级拉开，导致类间边界模糊，所有指标均显著下降。随着 λ 继续增大至 5×10^{-1} 和 1，损失函数对距离的惩罚过强，网络倾向于把特征无限外推，训练早期收敛速度变慢且后期出现欠拟合，表现为 ACC 跌至 0.421 4 和 0.371 7，NMI 跌至 0.341 7 和 0.297 0。纵向比较可见，模型在 $\lambda \in [10^{-2}, 10^{-1}]$ 内对权重扰动并不敏感，多项指标仅有 0.5%~1.0% 的自然波动；而当 λ 脱离该区间，性能快速劣化，表明过小 λ 无法提供足够聚类拉力，过大 λ 则抑制了特征表达能力。综上，本研究最终固定 λ 为 5×10^{-2} ，该取值兼顾了收敛速度、最终精度与对超参数扰动的鲁棒性，充分证明了损失权重设计的合理性。

表 5 不同损失函数权重取值的性能对比

Table 5 Performance comparison of different weight in loss function

λ	NMI	ARI	F	ACC	PUR
0	0.311 4	0.284 2	0.355 8	0.392 3	0.385 2
1×10^{-2}	0.372 2	0.350 8	0.404 5	0.478 6	0.456 2
5×10^{-2}	0.376 5	0.351 6	0.406 2	0.482 6	0.461 4
1×10^{-1}	0.371 7	0.348 2	0.392 6	0.473 4	0.454 8
5×10^{-1}	0.341 7	0.309 2	0.377 3	0.421 4	0.403 9
1	0.297 0	0.271 2	0.336 5	0.371 7	0.359 5

综上所述，系列消融实验清晰地证明：BYOL 自监督表征模块负责提升特征的一致性与稳定性，对比聚类机制则进一步增强类间可分性与类内聚合度，两者相辅相成、缺一不可；当任意模块被移除时，NMI 与 ACC 等核心指标均出现显著下降。此外，权重灵敏度分析表明式 (19) 中的损失权重 λ 在 $10^{-2} \sim 10^{-1}$ 对模型性能影响极小，其中 $\lambda=5 \times 10^{-2}$ 可取得最优综合表现，而过小或过大的 λ 都会削弱聚类效果。上述结果共同验证了本文框架在模块设计与超参数设置上的合理性与稳健性。

3 结束语

本文提出一种融合 BYOL 自监督表征学习与对比聚类机制的无监督通信信号调制识别方法。该模型既能提取信号片段的稳定特征，又能捕捉不同类别的区分特征。其中，BYOL 架构有助于学习高质量且一致的特征表示，而对比聚类机制可有效增强类内聚集性与类间可分性，最终实现对通信信号的准确分类。

综合实验结果表明，本文提出的 BYOL 驱动对比聚类框架在 RadioML2018.01A 数据集上显著超越传统聚类方法 (K-means、DBSCAN 等) 以及现有深度聚类代表算法 (CVCL、DeepCluster)；在 5 项主流评价指标 NMI、ARI、 F 、ACC 和 PUR 上均取得全面领先，其中相较于表现最佳的 DeepCluster，NMI 和 ACC 分别提升约 20.8% 与 18.8%。消融实验进一步验证了两大核心组件的必要性：BYOL 自监督表征能够稳定提取判别特征，对比聚类机制则有效拉大类间距离、压缩类内方差；缺失任一模块都会导致指标大幅下滑。权重灵敏度分析显示，损失权重 λ 在 $10^{-2} \sim 10^{-1}$ ，对性能影响甚微， $\lambda=5 \times 10^{-2}$ 时综合表现最佳，证实了超参数设置的稳健性。混淆矩阵结果表明，该方法对 AM-DSB-WC、FM、GMSK 等典型调制方式识别准确率接近理想值，并能在复杂信道条件下保持较强的抗混淆能力。综上，本文框架无需任何人工标签即可实现高精度调制识别，在实际无线通信信号识别和未知调制类型发现等场景中具有广阔的工程应用前景。

参考文献:

- [1] WEAVER C S, COLE C, KRUMLAND R, et al. The automatic classification of modulation types by pattern recognition[J]. Stanford Electronics Laboratories Technical Report 1829-2, 1969: 31.
- [2] POLYDOROS A, KIM K. On the detection and classification of quadrature digital modulations in broad-band noise[J]. IEEE Transactions on Communications, 1990, 38(8): 1199-1211.
- [3] BOITEAU D, LE MARTRET C. A General maximum likelihood framework for modulation classification[C]//Proceedings of International Conference on Acoustics. [S.l.]: IEEE, 1998: 2165-2168.
- [4] WU H C, SAQUIB M, YUN Z. Novel automatic modulation classification using cumulant features for communications via multipath channels[J]. IEEE Transactions on Wireless Communications, 2008, 7(8): 3098-3105.
- [5] 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 Xin, OUYANG Xi, YUAN Qiang. Automatic modulation classification using cumulant features for communications via multipath channels[J]. Journal of Information Engineering University, 2015, 16(1): 73-78.
- [6] MARCHAND P, LE MARTRET C, LACOUME J L. Classification of linear modulations by a combination of different orders cyclic cumulants[C]//Proceedings of the IEEE Signal Processing Workshop on Higher-Order Statistics. [S.l.]: IEEE, 1997: 47-51.
- [7] O'SHEA T J, CORGAN J, CLANCY T C. Convolutional radio modulation recognition networks[C]//Proceedings of International Conference on Engineering Applications of Neural Networks. Cham, Switzerland: Springer, 2016: 213-226.
- [8] O'SHEA T J, WEST N. Radio machine learning dataset generation with GNU radio[C]//Proceedings of the 6th GNU Radio Conference. Boulder, USA: [s.n.], 2016.
- [9] WANG F, WANG Y, CHEN X. Graphic constellations and DBN based automatic modulation classification[C]//Proceedings of IEEE 85th Vehicular Technology Conference (VTC Spring). [S.l.]: IEEE, 2017: 1-5.
- [10] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527-1554.
- [11] TANG B, TU Y, ZHANG Z, et al. Digital signal modulation classification with data augmentation using generative adversarial nets in cognitive radio networks[J]. IEEE Access, 2018, 6: 15713-15722.
- [12] HUANG S, CHAI L, LI Z, et al. Automatic modulation classification using compressive convolutional neural network[J]. IEEE Access, 2019, 7: 79636-79643.
- [13] XIE X, NI Y, PENG S, et al. Deep learning based automatic modulation classification for varying SNR environment[C]//Proceedings of 28th Wireless and Optical Communications Conference (WOCC). [S.l.]: IEEE, 2019: 1-5.
- [14] KUMAR Y, SHEORAN M, JAJOO G, et al. Automatic modulation classification based on constellation density using deep learning[J]. IEEE Communications Letters, 2020, 24(6): 1275-1278.
- [15] 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.
- [16] 刘尚合, 孙国至. 复杂电磁环境内涵及效应分析[J]. 装备学院学报, 2008, 19(1): 1-5.
LIU Shanghe, SUN Guozhi. Connotation and effect analysis of complex electromagnetic environment[J]. Journal of Equipment College, 2008, 19(1): 1-5.
- [17] ZHA X, QIN X, ZHOU Y, et al. Power of deep learning for amplitude-phase signal modulation recognition[C]//Proceedings of IEEE 8th Joint International Information Technology and Artificial Intelligence Conference (ITAIC). [S.l.]: IEEE, 2019: 454-458.
- [18] LIAO K, ZHAO Y, GU J, et al. Sequential convolutional recurrent neural networks for fast automatic modulation classification [J]. IEEE Access, 2021, 9: 27182-27188.
- [19] 胡国乐, 李鹏, 林事力, 等. 基于相位变换和CNN-BiLSTM的自动调制识别算法[EB/OL]. [2024-03-31]. <https://doi.org/10.20079/j.issn.1001-893x.230918001>.
HU Guole, LI Peng, LIN Shili, et al. Automatic modulation recognition algorithm based on phase transform and CNN-BiLSTM[EB/OL]. [2024-03-31]. <https://doi.org/10.20079/j.issn.1001-893x.230918001>.

- [20] SHI J, HONG S, CAI C, et al. Deep learning-based automatic modulation recognition method in the presence of phase offset [J]. *IEEE Access*, 2020, 8: 42841-42847.
- [21] MENG F, CHEN P, WU L, et al. Automatic modulation classification: A deep learning enabled approach[J]. *IEEE Transactions on Vehicular Technology*, 2018, 67(11): 10760-10772.
- [22] 杨宁,胡景明,张邦宁,等.低空智能网中基于多质心OpenMax的无人机开集识别方法[J]. *数据采集与处理*, 2024, 39(1): 60-70.
YANG Ning, HU Jingming, ZHANG Bangning, et al. Drone open set recognition method based on multi-center of gravity OpenMax in low-altitude intelligent networks[J]. *Journal of Data Acquisition and Processing*, 2024, 39(1): 60-70.
- [23] 陈洋, 廖灿辉, 张锐, 等. 基于自监督对比学习的信号调制识别算法[J]. *系统工程与电子技术*, 2023, 45(4): 1200-1206.
CHEN Yang, LIAO Canhui, ZHANG Kun, et al. A signal modulation identification algorithm based on self-supervised contrast learning[J]. *Systems Engineering and Electronics*, 2023, 45(4): 1200-1206.
- [24] LI M, LI O, LIU G, et al. Generative adversarial networks-based semi-supervised automatic modulation recognition for cognitive radio networks[J]. *Sensors*, 2018, 18: 3913.
- [25] 邵凯, 朱苗苗, 王光宇. 基于生成对抗与卷积神经网络的调制识别方法[J]. *系统工程与电子技术*, 2022, 44(3): 1036-1043.
SHAO Kai, ZHU Miaomiao, WANG Guangyu. Modulation recognition method based on generative adversarial network[J]. *Systems Engineering and Electronics*, 2022, 44(3): 1036-1043.
- [26] 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.
- [27] GRILL J B, STRUB F, ALTCHÉ F, et al. Bootstrap your own latent—A new approach to self-supervised learning[J]. *Advances in Neural Information Processing Systems*, 2020, 33: 21271-21284.
- [28] LI Y, HU P, LIU Z, et al. Contrastive clustering[C]//*Proceedings of the AAAI Conference on Artificial Intelligence*. [S.l.]: AAAI, 2021: 8547-8555.
- [29] 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.
- [30] MACQUEEN J. Some methods for classification and analysis of multivariate observations[C]//*Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability*. [S.l.]: University of California Press, 1967: 281-298.
- [31] ZHU Z, LEUNG H, HUANG X. Challenges in reconfigurable radio transceivers and application of nonlinear signal processing for RF impairment mitigation[J]. *IEEE Circuits and Systems Magazine*, 2013, 13(1): 44-65.
- [32] ELMAGHBUB A, HAMD AOUI B. Lora device fingerprinting in the wild: Disclosing RF data-driven fingerprint sensitivity to deployment variability[J]. *IEEE Access*, 2021, 9: 142893-142909.
- [33] SCHUCHERT A, HASHOLZNER R, ANTOINE P. A novel IQ imbalance compensation scheme for the reception of OFDM Signals[J]. *IEEE Transactions on Consumer Electronics*, 2001, 47(3): 313-318.

作者简介:



李道全(1964-),男,博士,教授,研究方向:无线网络、边缘计算, E-mail: 1261715631@qq.com。



姜云聪(1999-),男,硕士研究生,研究方向:调制识别、雷达信号处理, E-mail: jiangyuncong@stu.qut.edu.cn。



于全林(2001-),男,硕士研究生,研究方向:图像处理、目标检测, E-mail: yql200010831@163.com。



贾魏飞(2002-),男,硕士研究生,研究方向:调制识别、图像处理、目标检测, E-mail: 15265846624@163.com。



胡兆旭(1991-),通信作者,男,博士,研究方向:机器学习、信号处理、调制识别, E-mail: huzhaoxu@qut.edu.cn。

An Unsupervised Modulation Recognition Method for Communication Signals Based on BYOL and Contrastive Clustering

LI Daoquan, JIANG Yuncong, YU Quanlin, JIA Weifei, HU Zhaoxu*

(School of Information and Control Engineering, Qingdao University of Technology, Qingdao 266520, China)

Abstract: To address the heavy dependence on labeled data in practical radio environments, which limits reliable recognition of previously unseen (unknown) modulation types, this paper proposes an unsupervised modulation recognition method for communication signals based on bootstrap your own latent (BYOL) self-supervised representation learning and a contrastive clustering mechanism. Conventional modulation recognition algorithms are predominantly supervised and require large amounts of labeled data, which is often costly or even infeasible to obtain in real-world scenarios. Unsupervised and self-supervised approaches can alleviate this issue, but existing methods typically suffer from insufficient representation learning capacity and suboptimal clustering performance, and thus struggle to cope with complex channel conditions. The proposed method does not rely on any manual labels. First, we employ a BYOL framework with a dual-branch architecture to encode different sub-segments of the same signal, thereby learning intrinsic and stable representations in a self-supervised manner. Second, instance-level and cluster-level contrastive learning modules are introduced: The former enhances feature consistency across different augmented views of the same signal, while the latter improves the separability of different modulation types in the feature space, thereby enabling high-accuracy blind clustering of unknown modulation types. Experiments conducted on the public RadioML2018.01A dataset show that the proposed method outperforms existing algorithms by more than 10% in various clustering evaluation metrics. Ablation studies further confirm the critical roles of the BYOL module and the contrastive clustering mechanism in improving overall performance. Confusion-matrix analysis demonstrates that, at 10 dB, the proposed method achieves near-ideal recognition accuracy for typical modulation types such as amplitude modulation double-sideband with carrier (AM-DSB-WC), frequency modulation (FM), and Gaussian minimum shift keying (GMSK), and also exhibits strong robustness and anti-confusion capability for other more challenging modulation types. In summary, the proposed unsupervised modulation recognition method effectively alleviates the problem of label scarcity in real wireless communication scenarios and shows strong potential for practical deployment.

Highlights:

1. This paper proposes a BYOL-driven unsupervised contrastive clustering framework for communication signal modulation recognition without requiring labeled training data.
2. Signal segments from the same communication signal are constructed as positive sample pairs to improve self-supervised representation learning.
3. Experimental results on the RadioML2018.01A dataset verify that the proposed method achieves superior clustering performance over benchmark methods.

Key words: unsupervised learning; modulation recognition; contrastive clustering; self-supervised learning

Received: 2025-04-07; Revised: 2025-11-25

*Corresponding author, E-mail: huzhaoxu@qut.edu.cn.