

DOI:10.19651/j.cnki.emt.2416172

基于零样本学习和自编码器的调制信号识别研究*

童子滔^{1,2} 张治中¹ 张涛² 杜奕航²

(1. 南京信息工程大学电子与信息工程学院 南京 210044; 2. 国防科技大学第六十三研究所 南京 210007)

摘要: 针对深度学习模型在信号调制识别应用中无法有效识别未知调制方式的问题,提出了一种基于零样本学习和自编码器的信号调制识别模型,用于信号调制开集识别。通过自编码器提取调制信号的特征,引入交叉熵损失、中心损失和重构损失使得不同调制信号的特征能够良好分离,进一步根据特征空间的分布进行调制信号的开集识别。此外,利用解码器重构信号并加入训练,有效提升了模型识别率。实验结果表明,模型能够在提升已知类识别率的前提下对未知类进行区分,且对未知类的分类效果优于传统的开集识别方法,其中未知类识别率达到80%,已知类识别率稳定在95%左右。

关键词: 信号识别;零样本学习;卷积神经网络;自编码器;组合损失

中图分类号: TN971. +1 **文献标识码:** A **国家标准学科分类代码:** 510.40

Zero shot learning and autoencoder based modulation signal recognition

Tong Zitao^{1,2} Zhang Zhizhong¹ Zhang Tao² Du Yihang²(1. School of Electronic and Information Engineering, Nanjing University of Information Science and Technology, Nanjing 210044, China; 2. The 63rd Research Institute, National University of Defense Technology, Nanjing 210007, China)

Abstract: To address the challenge of effectively recognizing unknown modulation types in signal modulation recognition applications using deep learning models, this paper introduces a novel recognition model based on zero-shot learning and autoencoders for open set signal modulation recognition. Features of the modulation signals are extracted through an autoencoder, which incorporates cross-entropy loss, center loss, and reconstruction loss to ensure effective separation of features across different modulation types. Further, open set recognition of modulation signals is conducted based on the distribution of features in the feature space. Additionally, by incorporating the reconstructed signals back into training, the model's recognition accuracy is significantly enhanced. Experimental results demonstrate that the proposed model not only distinguishes unknown classes effectively, achieving an unknown class recognition rate of 80%, but also maintains a stable known class recognition rate of approximately 95%, outperforming traditional open set recognition methods.

Keywords: signal recognition; zero shot learning; convolutional neural network; autoencoders; combined loss

0 引言

对信号调制方式的识别是信号调制解调的前提和基础^[1],其中自动调制识别(automatic modulation recognition, AMR)技术在频谱监测、认知无线电等民用和军用领域^[2]发挥着重要作用。传统调制识别技术主要分为基于决策论的调制识别和基于机器学习的调制识别。基于决策论的调制识别^[3]使用手工提取信号特征,然后通过假设检验实现调制识别;基于机器学习的调制识别^[4]通过设计机器学习分类器,面对不同的信号类型和特点选取不同的分类器然后进行训练,找到最优的分类方案。但是这些方法相对

耗时低效,且容易受到噪声和非理想信道条件的影响^[5]。

近些年,深度学习(deep learning, DL)已经成为解决信号识别问题最流行的方法^[6]。基于深度学习的信号识别方法^[7]将特征选择和分类器合二为一,消除了手动设计特征的繁琐,具有良好的识别效果和鲁棒性。Zheng^[8]提出了一种采用基于浅层卷积神经网络(convolutional neural network, CNN)的多特征调制识别方法,这种方法强化了调制信号识别过程中由特征提取的各种特征的内部连接,从而提高了不同的信噪比(signal-to-noise ratios, SNRs)下信号识别的效果。文献[9]提出了一种基于深度

收稿日期:2024-06-03

* 基金项目:国家自然科学基金(62371463)项目资助

学习和软件定义无线电 (software defined radio, SDR) 的调制识别方法, 专门针对低 SNR 环境, 在低 SNR 环境下的无线信号调制识别提供了一个有前景的方向。Zha 等^[10] 研究使用了长短时记忆网络 (long short-term memory network, LSTM) 从时域中提取信号序列的深度特征, 实现了目标信号的端到端调制识别, 该方法对频率偏移和时序偏差表现出强大的鲁棒性。Qi 等^[11] 针对复杂多变的电子战环境下传统信号识别算法无法有效识别多样的雷达信号的问题, 提出一种基于 CNN 和时频分析的新型识别方法。

然而, 现有的调制识别工作都遵循闭集假设^[12], 在现实世界的应用中, 新的信号类别经常出现, 而模型仅针对具有一些有限已知调制方式的信号数据集进行训练。因此, 开放集识别被越来越多的应用于实际问题与工程中。Zhang 等^[13] 提出了一种基于深度学习的无线通信信号调制识别方法, 使用改进的广义端到端损失来训练设计的神经网络, 计算训练样本和质心向量之间的相似性, 以设置每种已知调制类型的自适应阈值。文献^[14] 提出了一种基于生成对抗性网络的技术来解决开集问题, 即识别 (radio frequency, RF) 发射机并对可信发射机进行分类。

随着越来越复杂的工程应用环境, 在某些情况下, 学习的模型不仅被要求能够区分未知类和已知类, 而且还应该能够区分不同的未知类, 零样本学习是当前解决此类问题的主要手段之一^[15]。零样本学习以能够对未知类进行分类而著称, 并已广泛应用于图像任务中, 文献^[16] 提出一种联合生成模型, 通过结合变分自编码器和生成对抗网络生成高质量未见类特征, 并使用对抗分类网络和自训练策略有效解决领域偏移问题, 显著提升了广义零样本学习的性

能。刘欢等^[17] 提出跨域对抗生成网络 (cross-domain adversarial generation network, CrossD-AGN), 将传统生成对抗网络和变分自编码器有机结合起来, 基于类级语义信息为未见类合成样本, 从而实现零样本分类。然而, 很少有将零样本学习用在信号识别上。

随着科技的高速发展以及电磁环境的日益复杂, 越来越多的未知信号逐渐涌现, 在模型训练阶段, 通常无法获得未知类别的有效样本, 导致识别准确率受到局限。本文提出了一种基于零样本学习与自编码器的信号调制识别模型来解决上述问题。首先利用自编码器提取调制信号的特征, 引入交叉熵损失、中心损失和重构损失的损失组合实现特征空间中类内聚拢类间分离, 然后通过解码器重构信号并加入训练从而强化各调制类别的特征边界, 最后根据特征空间的分布设计分类器实现信号的开集识别和未知信号之间的分类。所提方法能有效识别已知类别与未知类别信号并对其进行分类, 对已知类的识别率达到 95%, 未知类的识别率达到 80%。

1 模型架构

1.1 模型组成

本文提出的基于零样本学习与自编码器的信号调制识别模型由自编码器和分类器构成。模型先将原始信号输入编码器提取并保留有效特征, 然后通过解码器从特征空间中重构信号。分类器通过最小化损失函数更新神经网络参数和已知类的语义特征中心, 通过计算样本与已知类特征中心的距离然后设定对应阈值进行分类识别。模型框架如图 1 所示。

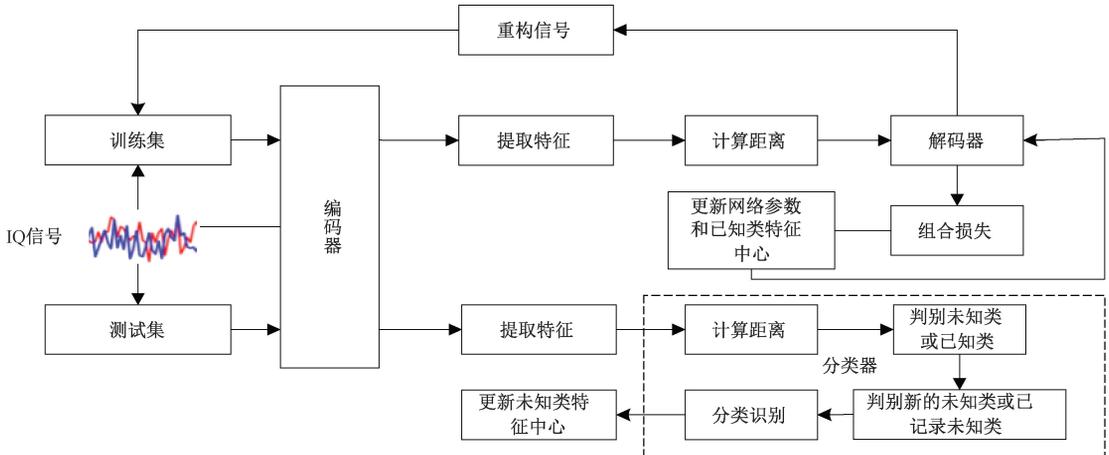


图 1 模型框架

Fig. 1 Model framework

1.2 自编码器

自编码器是一种深度学习模型, 它的目标是学习一个能够有效编码和解码输入数据的表示^[18]。在本文所提出的模型中, 自编码器用来保留特征空间中的有效特征并用于重构信号。自编码器由编码器和解码器共同组成。自

编码器结构如图 2 所示。

1) 编码器

编码器采用 CNN 对信号特征进行自动提取。网络由四个卷积层和两个全连接层构成。每个卷积层由卷积操作、批量归一化和激活函数组成, 目的是从信号中提取局

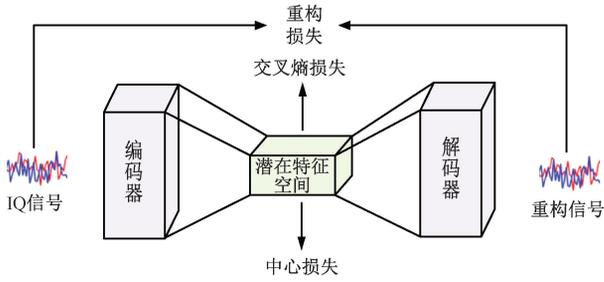


图2 自编码器结构

Fig. 2 Autoencoder architecture

部和全局特征。模型中的最大池化和平均池化技术进一步强化了特征提取并优化了计算效率。经过所有卷积操作后,得到的特征被扁平化并传递到全连接层,将高维特征映射到一个更紧凑、具有代表性的形式,并为信号类别提供预测。为增强模型鲁棒性并防止过拟合,模型在卷积和全连接层之间都加入了 Dropout 层,并采用了批量归一化。

2) 解码器

解码器的目标是从特征空间中重构原始信号数据,它由反卷积反池化和全连接层组成。反卷积和反池化操作是卷积和池化操作的逆操作。为了方便理解,本文假设两

个向量 $a, b \in R^n$, a 是输入向量, b 是输出向量。 $b = Ma$ 即可表示为卷积操作,这里 M^T 是卷积矩阵,这个矩阵大部分元素都是 0。假设 \tilde{M} 是与 M^T 形状相同的卷积矩阵,反卷积操作可以表示为 $a = \tilde{M}b$,图 3 展示了核为 3×3 的卷积与反卷积,其中步长和填充分别为 1 和 0。

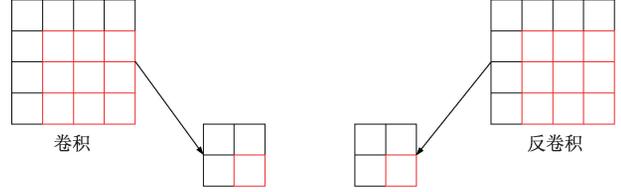


图3 卷积与反卷积图

Fig. 3 Convolution and deconvolution diagram

反池化具体可以分为最大反池化和平均反池化。最大反池化保留了在最大池化过程中的最大值位置信息,然后在相应的位置恢复这些最大值,并将其他位置设置为零。而平均反池化则是通过复制的方式来扩展特征图。在反向传播中,损失函数相对于 b 的梯度可以表示为:

$$\frac{\partial \text{Loss}}{\partial b} = \tilde{M}^T \frac{\partial \text{Loss}}{\partial a} \quad (1)$$

自编码器网络结构参数如表 1 所示。

表 1 自编码器网络结构参数

Table 1 Autoencoder network architecture parameters

编码器	解码器
输入	输入
Conv 64, (3×3), stride 1, Relu, BN	Conv 64, (3×3), stride 1, Relu, BN
MaxPool (1×2), stride (1,2)	MaxUnpool (1×2), stride (1,2)
Conv 128, (3×3), stride 1, Relu, BN	Conv 128, (3×3), stride 1, Relu, BN
MaxPool (1×2), stride (1,2)	MaxUnpool (1×2), stride (1,2)
Conv 256, (3×3), stride 1, Relu, BN	Conv 256, (3×3), stride 1, Relu, BN
MaxPool (1×2), stride (1,2)	MaxUnpool (1×2), stride (1,2)
Conv 512, (3×3), stride 1, Relu, BN	Conv 512, (3×3), stride 1, Relu, BN
AvgPool (2×2), stride 2	Upsample scale factor 2
FC 8 * 512 to 1024, Relu, BN	FC 1024 to 8 * 512, Relu, BN
FC 1024 to 512, Relu, BN	FC 512 to 1024, Relu, BN
FC 512 to feature_dim, Relu, BN	FC feature_dim to 512, Relu, BN
输出 num_class	

1.3 分类器

分类器基于潜在的特征空间来区分已知类和未知类。对于每个已知类别 k , 编码器提取和计算相应的特征中心向量。特征中心向量是类别 k 中所有训练样本的特征的平均值,它的计算公式如下:

$$S_k = \frac{\sum_{j=1}^m \delta(y_j = k) F(x_j)}{\sum_{j=1}^m \delta(y_j = k)} \quad (2)$$

其中, S_k 是特征中心向量; $F(x_j)$ 表示 CNN 提取的

样本语义特征; $\delta(y_j = k)$ 是个条件等式,当括号内条件满足时 $\delta(y_j = k) = 1$, 否则为 0。当一个测试信号 I 出现并且得到 $F(I)$ 时,可以测量向量 $F(I)$ 和每个之 S_k 间的差异。定义 $F(I)$ 和 S_k 之间的距离如下:

$$d(F(I), S_k) = (F(I) - S_k)^T A_k^{-1} (F(I) - S_k) \quad (3)$$

分类器在特征空间中通过两步进行类别识别。第 1 步是区分已知类和未知类,第 2 步是判断测试信号属于已经出现过的未知类还是新的未知类。在第一步中,通过比

较阈值 Θ_1 和最小距离 d_1 来进行已知类和未知类的判断。即：

$$d_1 = \operatorname{argmin}_k d(F(I), S_k) \quad (4)$$

其中, d_1 是测试样本特征 $F(I)$ 与所有已知类语义中心向量 S_k 的最小距离。如果 $d_1 < \Theta_1$, 则预测结果属于已知类, 否则属于未知类。阈值 Θ_1 的选择基于三西格玛规则, 该规则是一种常用的异常值识别方法。因为本文的模型假设每个类别的语义特征服从多元高斯分布, 因此本文可以根据三西格玛规则将阈值 Θ_1 设定为样本语义特征的平均距离的 3 倍, 即 $\Theta_1 = \lambda_1 \times 3\sqrt{t}$, 其中 λ_1 是一个控制参数, 用于调整阈值的大小, t 是高斯分布的维度。

对于被分类为未知类的测试样本, 定义了 R 为已记录的未知类的集合, S_R 为 R 中的特征中心向量的集合。对于一个未知类的样本, 如果是 R 空集 (即这是第一次遇到未知类的样本), 那么会在 R 中添加一个新的标签, 并将测试样本 I 的语义特征向量 $F(I)$ 设置为新的特征中心向量 S_{R_1} , 然后标记 $y_1 = R_1$ 。如果 R 不是空集 (即之前已经有未知类的样本被记录了), 那么会计算测试样本 I 与 $F(I)$ 中的所有向量的最小距离 d_2 (计算方式如 d_1), 并与阈值 Θ_2 进行比较。如果 $d_2 > \Theta_2$, 则表示这个测试样本 I 属于一个新的未知类, 会在 R 中添加一个新的标签 R_{nR+1} 并标记 $y_1 = nR + 1$ 。如果 $d_2 < \Theta_2$, 则表示这个测试样本 I 属于已知的未知类。然后, 会更新对应类别的特征中心向量, 分类器流程如图 4 所示。

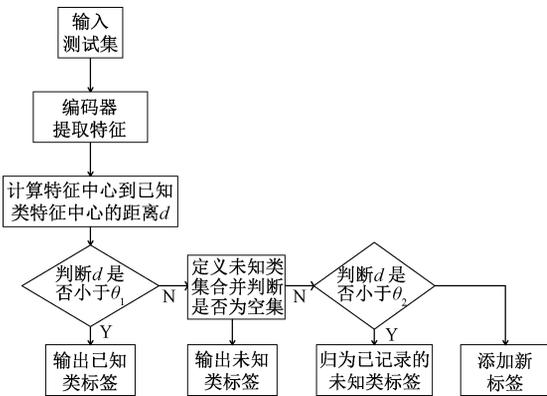


图 4 分类器流程

Fig. 4 Classification module process

1.4 损失函数设计

在模型的训练过程中, 利用梯度反向传播技术来最小化损失, 从而优化模型的性能。为了确保这些语义特征可以有力地辅助模型区分已知和未知的类别, 选择合适的损失函数以指导网络的特征提取变得至关重要。模型将交叉熵损失、中心损失和重构损失组合实现总损失函数设计。

为了最小化语义空间中的类内变化, 同时保持类间语义特征的良好分离, 模型使用了中心损失函数。中心损失

表示如下:

$$L_{\alpha} = \frac{1}{2N} \sum_{i=1}^N \|F(x_i) - C_{y_i}\|_2^2 \quad (5)$$

式中: C_{y_i} 表示 y_i 类的语义中心向量, 在每次迭代中, 需要对每个类的特征进行平均, 并且 C_{y_i} 需要随着 y_i 语义特征的变化而更新。在应用中根据 $C_{y_i} \leftarrow C_{y_i} - \Delta C_{y_i}$ 每批次进行更新, 其中 α 为学习率, ΔC_{y_i} 的计算方法如下:

$$\Delta C_{y_i} = \frac{\sum_{i=1}^N \delta(y_i = y_j)(C_{y_i} - F(x_i))}{1 + \sum_{i=1}^N \delta(y_i = y_j)} \quad (6)$$

交叉熵损失作为一个有效的度量手段, 被用于强化模型对不同类别的鉴别能力。它衡量了模型预测的概率分布与实际的概率分布之间的差距。该损失的数学形式如下所示: 使用交叉熵损失来控制 and 预测模型的情况。其表达式如下:

$$L_{ce} = -\frac{1}{N} \sum_{i=1}^N y_i \log(C(F(x_i))) \quad (7)$$

模块还引入了重构损失 L_r , 这是一个评估原始信号数据和重构信号数据之间差异的指标。在这里, 重构损失被定义为所有重构信号和原始信号差的平方的平均值, 即:

$$L_r = \frac{1}{2N} \sum_{i=1}^N \|D(F(x_i)) - x_i\|_2^2 \quad (8)$$

其中, x_i 是原始信号; $D(F(x_i))$ 是对原始信号 x_i 的重构; N 是信号的总数。这个损失函数的直观理解是, 如果一个模型能够更完整地重构出原始信号, 那么它在语义特征空间中所包含的有效信息就会更多。通过最小化重构损失, 本文可以训练出一个能够保留原始信号中大部分信息的模型。本文还提出了一种思路, 即将重构出的信号保留, 与原始信号一同加入训练, 从而达到强化已知类与未知类边界的作用。模型的总损失函数由交叉熵损失、中心损失和重建损失组合而成:

$$L_t = L_{ce} + \lambda_{\alpha} L_{\alpha} + \lambda_r L_r \quad (9)$$

权重 λ_{α} 和 λ_r 用于平衡 3 个损失函数。

2 实验过程及结果

为了评估所提模型的性能, 实验使用数据集 SIGNAL-2020 002 进行验证。数据集由 11 种调制类型组成, 它们是 BPSK、QPSK、8PSK、16QAM、64QAM、PAM4、GFSK、CPFSK、B-FM、AM-DSB 和 AMSSB。每种类型由 20 000 个帧组成。数据以每符号 8 个样本的速率调制, 而每帧 128 个样本。信道损伤通过加性高斯白噪声、瑞利衰落、多径信道和时钟偏移的组合来建模。每个调制类型 20 000 个样本 2×128 特征维度 20 个不同的 SNR, 范围为 $-20 \sim 18$ dB, 步长为 2, 过滤掉 SNR 小于 16 的样本, 只留下更纯净、更高质量的部分作为本文实验中的整体数据集。本文将已知类的 80% 的样本组成整个训练集, 20% 组成已知测试集, 对于未知类, 只需要一个测

试集,它由20%的未知样本组成。表2为数据集 SIGNAL-2020 002 信息。

表2 SIGNAL-2020 002 信息

Table 2 SIGNAL-2020 002 information

类别数	信噪比/ dB	每类别各 信噪比样本数	总样 本数	特征 维度
11	(-20,18)	1 000	220 000	2×128

表3 训练集、测试集数据信息

Table 3 Training and test set data information

数据分割	信噪比/dB	信号类别	总样本数
训练集	16,18	9/10类已知调制信号+9/10类重构信号	14 400/16 000个样本
测试集	16,18	11类调制信号(9/10类已知调制类别+2/1类未知调制类别)	3 600/4 000个已知类样本 +400/800个未知类样本

训练设置250次迭代,学习率设置为0.001,中心损失的权重 λ_c 设置为0.03,重构损失的权重 λ_r 设置为10。在实验过程中,当epoch大于50轮时,每25个epoch保存模型参数并获取从训练集提取的语义特征,图5为训练过程中总损失、交叉熵损失、中心损失、重构损失的函数曲线。

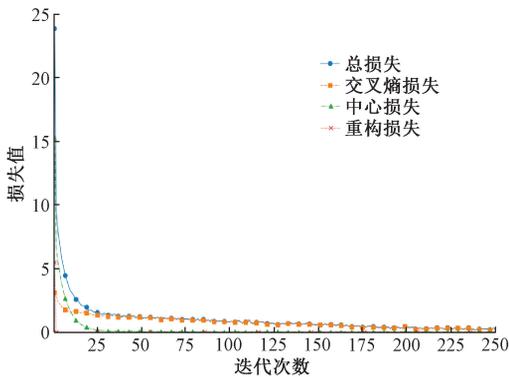


图5 训练损失

Fig. 5 Training loss

可以看到函数在前50次迭代收敛较快,而后逐渐趋于平缓,其中重构损失在第2次迭代时就已经完全收敛。实验对象为11类调制信号,分别设置1类未知类与2类未知类进行实验。首先,选择8PSK作为一类未知类,再设置BPSK、CPFSK作为两类未知类,为了体现模型中通过自编码器引入重构信号加训练的优势,直接将原始信号输入系统进行训练,在未提取重构信号混入原始信号的前提下也做了同样实验,图6为利用T-SNE降维可视化下的聚类流形,图6(a)与(b)分别展示了未加重构信号时1类未知类、2类未知类情况下训练阶段特征空间分布;图6(c)与(d)为加入重构信号后两种情况下各信号的特征空间分布。可以明显看到,加入重构信号后,已知类的类内聚集

2.1 实验过程

首先训练所有已知类信号,通过最小化重构损失,自编码器可以学习到一个相对合适的特征表示,从而尽可能的还原原始信号,保存模型权重,利用预训练好的模型中的自编码器对信号进行重构,将重构后的信号保存并添加到原始信号中,一同输入模型进行训练。因为只需关注原调制类别的分类识别情况,所以直接使用未重构的原始信号进行测试,减少模型运算量。训练集和测试集的数据信息如表3所示。

度和类间分离度更优,便于模型识别分类。在未进行重构时,GFSK聚类和SSB-AM聚类高度重叠,BPSK聚类和QPSK聚类也有小部分重叠。在加入重构信号训练后,设置1类未知类的情况下,GFSK聚类和SSB-AM聚类只剩少部分重叠,2类未知类时,它们二者的分离度也优于重构前。而无论是1类未知类还是2类未知类,BPSK聚类和QPSK聚类在重构后都实现了完美分离。

2.2 实验结果

图7(a)和(b)分别展示了1类未知类与2类未知类情况测试集输入模型后得到的混淆矩阵(不包含未知类)。从图中看到,在只设置1类未知类时,模型对已知类调制信号的平均识别率达到了98%,而设置2类未知类时对已知类的平均识别率下降到95%,这也符合开集识别的基本假设,即当未知类数量增加时,模型对已知类的识别能力会呈下降趋势。这可能是当只有一类未知类时,模型可以更加集中地学习和区分已知类和未知类之间的差异,而不会被多个未知类之间的差异所干扰。这为以后的开集识别提供了一个有趣的研究方向,即如何合理地设置未知类以优化已知类的识别性能。

用VGG对全部调制信号进行闭集测试,闭集混淆矩阵如图8所示。对比发现,虽然模型是通过各个类别语义特征的向量距离来分类的,但相比较传统的神经网络分类方法,即便在设置未知类的前提下,模型对于已知类的识别依然保持不错的水准,甚至超出了使用VGG闭集识别的识别率。

2.3 消融实验

1) 损失函数消融

为了解释每个损失函数的必要性,进行了组合损失函数的消融实验。图9为损失函数消融实验,给出了在训练过程中不设置中心损失和重建损失以及两者都不设置(只

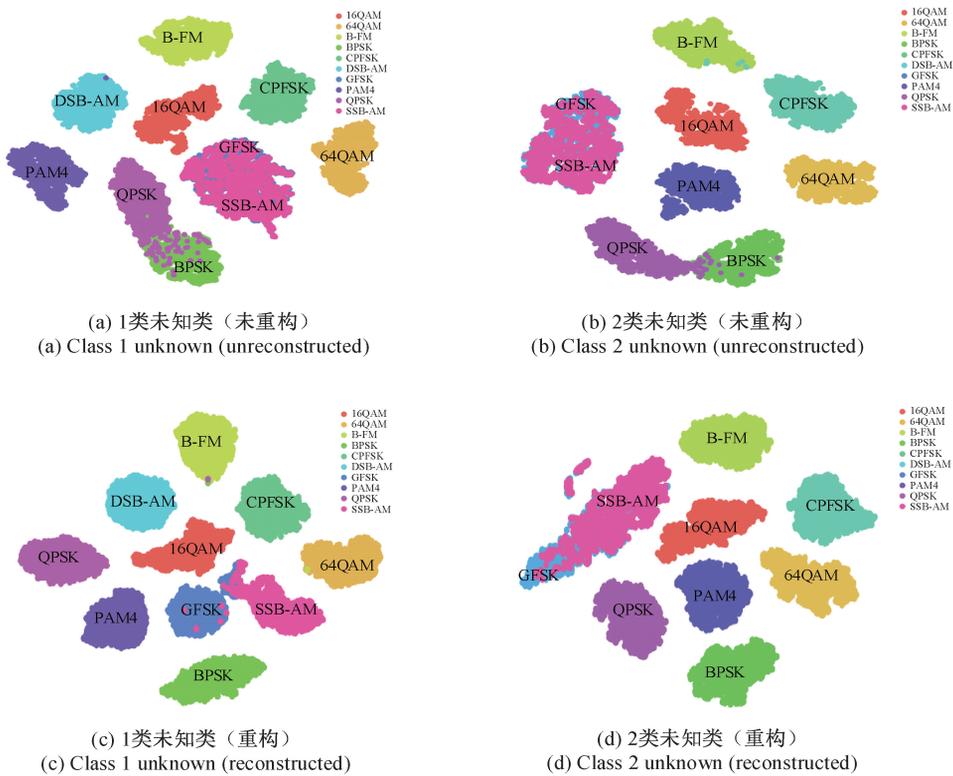


图 6 特征空间分布

Fig. 6 Feature space distribution

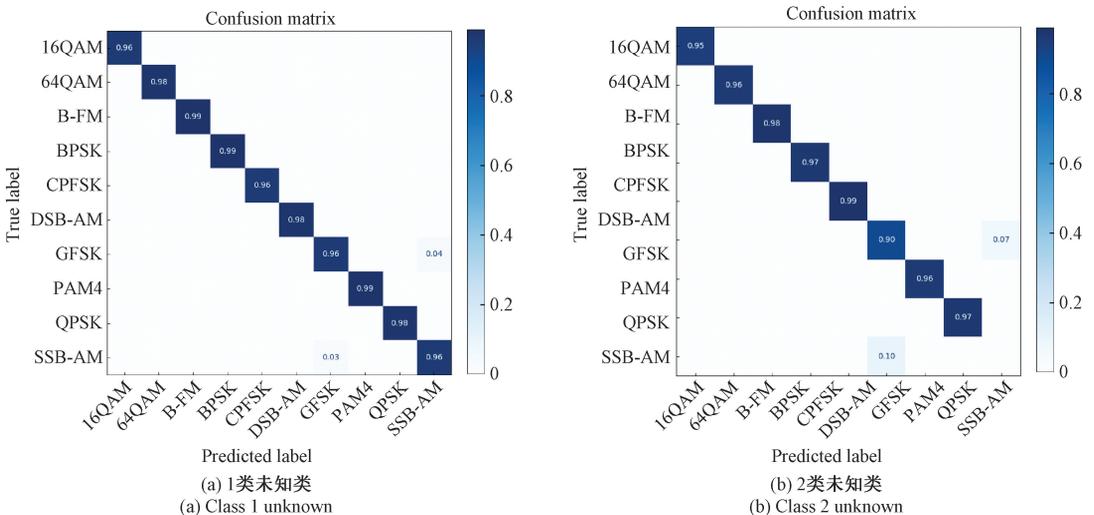


图 7 开集混淆矩阵(不包含未知类)

Fig. 7 Open set confusion matrix (excluding unknown classes)

有交叉熵)的情况下的已知类别调制信号的平均识别率。

可以看到,在 175 轮迭代之后,模型所使用的由 3 种损失组合而成的损失函数对于调制信号的平均识别率要领先于其他 3 种情况。交叉熵损失作为分类任务中的关键损失函数,实验对其进行保留,测试结果也展示了它对于模型整体识别率的核心作用。而排除中心损失或者重构

损失中的任何一个,训练过程中的整体识别率以及最佳识别率都会略有下降,这也说明这两类损失函数对已知类和未知类的区分都起到了重要的作用。通过最小化中心损失,模型能够更好的实现类内聚拢和类间分离,对于同时存在已知类与未知类的闭集识别任务,中心损失往往发挥不错的效果,同时为分类器基于距离进行判别分类计算了

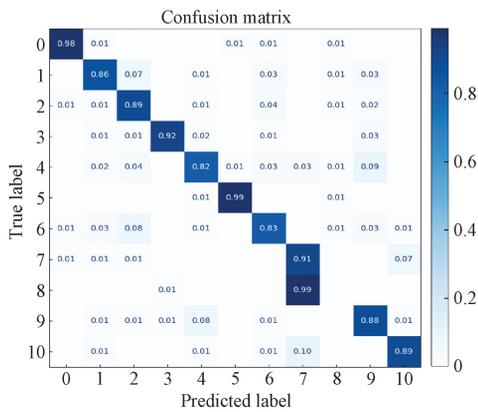


图8 闭集混淆矩阵

Fig. 8 Closed set confusion matrix

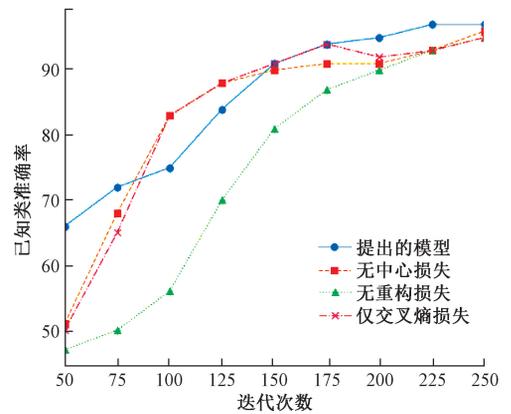


图9 损失函数消融实验

Fig. 9 Loss function ablation experiment

先决条件。而重构损失可以帮助网络更好地理解 and 捕捉数据的内在结构和模式,确保了特征表示不仅适用于分类任务,还能够反映出信号的基本特性,重构的结果可以作为一个直观的指标来评价模型学习到的特征的有效性和完整性,为后续解码器重构信号建立了基准。

2) 重构信号消融

进一步对解码器产生重构信号这一步骤进行消融实

验,实验参数同2.1小节。实验首先在不剔除解码器,即加入重构损失的前提下,不将解码器产生的重构信号提取出来,而直接训练并测试原始调制信号。再将重构信号加入原始信号中一同训练,并只将原始调制信号输入分类器进行分类识别。对1类未知类和2类未知类都进行了重构的消融实验,对比两者在已知类别和未知类别的识别率上的差异,表4给出了具体识别结果。

表4 识别结果

Table 4 Recognition results

类别	识别率			
	1个未知类		2个未知类	
	加入重构信号	未加重构信号	加入重构信号	未加重构信号
16QAM (0)	96%	87%	95%	94%
64QAM (1)	98%	84%	96%	86%
8PSK(2)	91% (未知类)	79% (未知类)	98%	78%
B-FM(3)	98%	80%	70% (未知类)	67% (未知类)
BPSK(4)	98%	71%	97%	75%
CPFSK (5)	98%	93%	90% (未知类)	50% (未知类)
DSB-AM(6)	97%	76%	99%	62%
GFSK(7)	96%	62%	90%	94%
PAM4(8)	99%	92%	96%	78%
QPSK(9)	98%	64%	96%	60%
SSB-AM(10)	96%	64%	88%	58%
已知类平均识别率	97%	77%	95%	72%
未知类平均识别率	91%	79%	80%	58.5%

设置两类未知类时,未知类的识别率明显有所降低,但相比未加重构信号时仍有一定提升。因为模型使用语义特征作为分类依据,当出现更多未知类时也就相对应出现了更多未经过训练的语义特征,从而不能形成很好的类内聚拢和类间分离。通过图6的特征空间分布可以直观看到,无论是重构信号前还是重构信号后,SSB-AM与GFSK的特征分布都有一部分重叠,这也导致SSB-AM在

所有类别中识别率最低,最易产生混淆。即使如此,在加入重构信号训练后,SSB-AM的识别率还是分别提升到了96%和88%。通过分析表4的识别结果发现,无论是设置一类未知类还是两类未知类,在未将重构出的信号混入原始信号一起训练之前,已知类别的总体平均识别率总是维持在70%~80%之间,经过后期设置不同未知类进行多组实验后发现,直接将原始信号输入零样本模型后的已知类

识别率几乎很难突破 80%，而经过自编码器重构一遍后重新训练，模型的识别率能稳定在 90% 以上。相比于已知类别，未知类的识别率的稳定性是有所下降的，其实一个特征很难学习的类别对于模型来说本来就是一个挑战，当它在模型中扮演未知类的时候，与已知类的界限会更难区分，所以如何选择未知类别对于识别率的影响还是客观存在的。

2.4 对比实验

1) 不同开集方法对比

为了证明所提方法的优越性，将所提方法与两种开集识别领域方法（OpenMax^[19]，SR2CNN^[20]）进行对比。OpenMax 为输出向量附加一个额外维度，以表示当前样本未知的概率实验结果，SR2CNN 提出了一种基于距离的开集分类器，来划分已知类与未知类界限。在同样设置一类未知类进行实验时，不同开集识别方法性能如表 5 所示。显然，从平均准确率看，所提方法优于两种开集识别方法，尤其在未知类别区分度上，本章方法明显优于其他两种方法，分别提升了 41% 和 12%。

表 5 不同开集识别方法性能对比

Table 5 Performance comparison of different open set recognition methods

方法	本章方法	OpenMax	SR2CNN
已知类准确率	0.97	0.86	0.77
未知类准确率	0.91	0.50	0.79
平均准确率	0.94	0.68	0.78

2) 不同信噪比下对比

为了评估所提模型的鲁棒性，在测试时使用信噪比 -20~18 dB 的调制信号作为测试样本，取平均准确率作为衡量指标。不同信噪比下已知类的识别情况如图 10 所示。

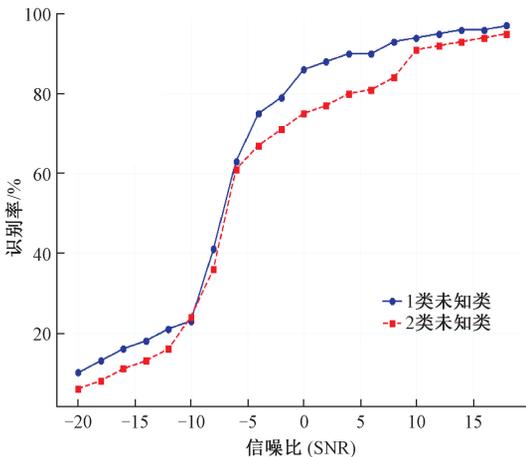


图 10 不同信噪比下识别率

Fig. 10 Recognition rate under different signal-to-noise ratios

从图 10 中可以看出，随着信噪比的上升，两种情况的识别率曲线都呈上升趋势，因为当信噪比高时，信号中的有用信息比噪声的干扰要多，这使得信号更加明显和清晰，模型更容易区分出信号和噪声。当信噪比低于 -7 dB 时，无论是设置 1 类未知类还是 2 类未知类，识别率基本都低于 40%，当信噪比在 -7~-5 dB 之间，识别率有明显的抖升，上升到 60% 以上，而后稳步提高，总体上而言，设置 1 类未知类的识别率要高于 2 类未知类，这也符合前面实验的分析，但已知类的识别率在一个高信噪比条件下，都能达到 95% 以上，且即使设置 2 类未知类，模型的整体效果也不会与 1 类未知类的情况有太大差距，达到实验预期效果。

3 结 论

本文提出了一种基于零样本学习和自编码器的调制信号识别模型。使用自编码器重构数据集中调制信号，带有交叉熵损失、中心损失和重构损失组成损失函数的 CNN 对重构出的信号与原始信号中的已知类数据样本进行训练，用训练好的网络模型提取预测测试集中调制信号的特征，在特征空间中通过特征向量的分布实现已知类和未知类的识别分类。实验表明，本文提出的模型识别率要优于传统开集识别方法，在开集识别增加未知类别数目至两类 的情况下，对已知类识别率都能达到 95% 以上，未知类识别率也能稳定在 80% 左右，说明模型可以成功地提取信号的精确特征，并区分已知类和未知类。现如今成熟的信号开集识别方法大多还是满足能够在测试过程中拒绝未知类，但稳定且准确的给未知类打上标签从而进行分类仍然是一个难点，同时在低信噪比条件下如何提高模型的鲁棒性，也是未来研究的一个方向。

参考文献

- [1] SUN Y. Research on modulation recognition of radio signal[J]. Wuhan Hujian Keji, 2020, 17: 9-10.
- [2] 钱磊, 吴昊, 乔晓强, 等. 基于特征融合的调制识别增强与迁移演化[J]. 电子测量技术, 2022, 45(18): 153-160.
QIAN L, WU H, QIAO XQ, et al. Modulation recognition enhancement and migration evolution based on feature fusion [J]. Electronic Measurement Technology, 2022, 45(18): 153-160.
- [3] ABDELBAR M, TRANTER W H, BOSE T. Cooperative cumulants-based modulation classification in distributed networks [J]. IEEE Transactions on Cognitive Communications and Networking, 2018, 4(3): 446-461.
- [4] ZHANG X, GE T. Automatic modulation recognition of communication signals based on instantaneous statistical characteristics and SVM classifier[C]. 2018

- IEEE Asia-Pacific Conference on Antennas and Propagation(APCAP). IEEE, 2018: 344-346.
- [5] MA K, ZHOU Y, CHEN J. CNN-based automatic modulation recognition of wireless signal [C]. 2020 IEEE 3rd International Conference on Information Systems and Computer Aided Education (ICISCAE). IEEE, 2020: 654-659.
- [6] TAO G H, LIAO K S, ZHOU L. A novel signal modeling and modulation classification method with deep learning [J]. Electronic Warfare Technology, 2019, 34: 10-15.
- [7] 王满喜, 史明佳, 陆科宇, 等. 电磁信号调制识别中的对抗性攻击技术研究[J]. 无线电通信技术, 2022, 48(6): 1098-1104.
WANG M X, SHI M J, LU K Y, et al. Research on adversarial attacks technology in modulation recognition [J]. Radio Communication Technology, 2022, 48(6): 1098-1104.
- [8] ZHENG Z. Multi-feature modulation signal recognition based on deep learning [C]. 2022 9th International Conference on Dependable Systems and Their Applications(DSA). IEEE, 2022: 1069-1070.
- [9] ALZAQ O H, ALREHAILI J, USTUNDAG B B. Low-SNR modulation recognition based on deep learning on software defined radio [C]. 2022 5th International Conference on Advanced Communication Technologies and Networking (CommNet). IEEE, 2022: 1-6.
- [10] ZHA X, QIN X, ZHOU Y, et al. Power of deep learning for amplitude-phase signal modulation recognition [C]. 2019 IEEE 8th Joint International Information Technology and Artificial Intelligence Conference(ITAIC). IEEE, 2019: 454-458.
- [11] QI Z, CHEN Y, LIU Y, et al. Radar signal recognition based on deep convolutional neural network in complex electromagnetic environment [C]. 2022 3rd China International SAR Symposium (CISS). IEEE, 2022: 1-5.
- [12] 汪浩, 吴云树. 融合神经网络与瞬时自相关分区特征的自动调制分类方法研究[J]. 国外电子测量技术, 2019, 38(11): 52-56.
WANG H, WU Y SH. Research on automatic modulation classification method based on neural network and instantaneous autocorrelation partition feature [J]. Foreign Electronic Measurement Technology, 2019, 38(11): 52-56.
- [13] ZHANG X, LI T, GONG P, et al. Open set recognition of communication signal modulation based on deep learning [J]. IEEE Communications Letters, 2022, 26(7): 1588-1592.
- [14] ROY D, MUKHERJEE T, CHATTERJEE M, et al. Detection of rogue RF transmitters using generative adversarial nets [C]. 2019 IEEE Wireless Communications and Networking Conference (WCNC). IEEE, 2019: 1-7.
- [15] WANG Z, YE X, WANG C, et al. Network embedding with completely-imbalanced labels [J]. IEEE Transactions on Knowledge and Data Engineering, 2020, 33(11): 3634-3647.
- [16] GAO R, HOU X, QIN J, et al. Zero-VAE-GAN: Generating unseen features for generalized and transductive zero-shot learning [J]. IEEE Transactions on Image Processing, 2020, 29: 3665-3680.
- [17] 刘欢, 郑庆华, 罗敏楠, 等. 基于跨域对抗学习的零样本分类[J]. 计算机研究与发展, 2019, 56(12): 2521-2535.
LIU H, ZHENG Q H, LUO M N, et al. Cross-domain adversarial learning for zero-shot classification [J]. Journal of Computer Research and Development, 2019, 56(12): 2521-2535.
- [18] 郭小萍, 张志朋, 李元. 基于邻域降噪正交自编码器的工业过程故障检测 [J]. 电子测量技术, 2024, 45(21): 142-147.
GUO X P, ZHANG ZH P, LI Y. Neighborhood denoising quadrature autoencoder based fault detection for industrial process [J]. Electronic Measurement Technology, 2024, 45(21): 142-147.
- [19] BENDALE A, BOULT T. Towards open set deep networks [C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA: IEEE, 2016: 1563-1572.
- [20] DONG Y, JIANG X, ZHOU H, et al. SR2CNN: Zero-shot learning for signal recognition [J]. IEEE Transactions on Signal Processing, 2021, 69: 2316.

作者简介

童子滔, 硕士研究生, 主要研究方向为通信辐射源个体识别、深度学习。

E-mail: tzt0911@163.com

张治中, 教授, 博士生导师, 主要研究方向为移动通信与信息处理、通信网测试与仪表技术、移动大数据、物联网。

张涛(通信作者), 副研究员, 博士, 主要研究方向为频谱智能感知。

E-mail: ztcool@126.com

杜奕航, 副研究员, 博士, 主要研究方向为智能频谱认知与管控。