

# 基于确定性过采样的不平衡航空通信信号调制识别

李浩然<sup>1</sup>, 王艺然<sup>1</sup>, 白静<sup>1</sup>, 肖竹<sup>2</sup>

(1. 西安电子科技大学人工智能学院, 西安, 710071; 2. 湖南大学信息科学与工程学院, 长沙, 410082)

**摘要** 针对航空通信中, 复杂电磁环境下的调制信号分类任务数据不平衡以及少数类信号样本的缺乏导致分类器的性能下降的问题, 提出了一种基于确定性过采样技术的不平衡航空通信调制信号分类方法。该方法通过合成少数类信号样本, 平衡数据集, 从而减少数据不平衡对分类器的负面影响。基于 RadioML 2016.10a 数据集, 选择 11 种调制方式, 在 -8 dB、-4 dB、0 dB、4 dB、8 dB 信噪比下构建了 4 种不平衡场景进行验证。实验结果表明, 相较于不平衡数据集, 文中所提方法在 MsmcNet、ResNet50 和 DenseNet121 3 种网络模型上, 分类准确率分别提高了 2.78%、0.92%、3.45%。与传统的 SMOTE 方法相比, 所提方法在处理多类不平衡问题上表现出更好的分类性能。该方法能够有效提高调制信号分类任务中的准确率, 尤其是在复杂电磁环境下的航空通信场景中。

**关键词** 信号调制分类; 多类不平衡信号; 过采样; 确定性合成; 数据分布

**DOI** 10.3969/j.issn.2097-1915.2025.03.003

**中图分类号** TN911.7 **文献标志码** A **文章编号** 2097-1915(2025)03-0018-08

## A Signal Modulation Classification for Unbalanced Aviation Communication Signals Based on Deterministic Oversampling

LI Haoran<sup>1</sup>, WANG Yiran<sup>1</sup>, BAI Jing<sup>1</sup>, XIAO Zhu<sup>2</sup>

(1. School of Artificial Intelligence, Xidian University, Xi'an 710071, China; 2. College of Computer Science and Electronic Engineering, Hunan University, Changsha 410082, China)

**Abstract** In aeronautical communications, because of that data are imbalance, and being lack of minority class signal samples, there is a drop in the classifier performance in modulation signal classification tasks under complex electromagnetic environments, this paper proposes a classification method for unbalanced modulation signals based on deterministic oversampling. The method synthesizes minority class signal samples to balance the dataset and reduce the impact of data imbalance on classification performance. Based on the method at the RadioML 2016.10a dataset, 11 modulation types are selected under 5 signal-to-noise ratios (-8 dB, -4 dB, 0 dB, 4 dB, 8 dB) and 4 imbalance scenarios are constructed. The experimental results show that compared to the imbalanced dataset, the proposed method improves classification accuracy by 2.78%, 0.92% and 3.45% on MsmcNet, ResNet50, and DenseNet121 network models res-

**收稿日期:** 2024-05-27

**基金项目:** 国家自然科学基金(62276206); 航空科学基金(2023Z071081001)

**作者简介:** 李浩然(2000-), 男, 山东泰安人, 硕士生, 研究方向为智能信号处理。E-mail: hr\_lee@stu.xidian.edu.cn

**通信作者:** 白静(1982-), 女, 陕西西安人, 教授, 博士生导师, 研究方向为智能信号处理。E-mail: baijing@mail.xidian.edu.cn

**引用格式:** 李浩然, 王艺然, 白静, 等. 基于确定性过采样的不平衡航空通信信号调制识别[J]. 空军工程大学学报, 2025, 26(3): 18-25. LI Haoran, WANG Yiran, BAI Jing, et al. A Signal Modulation Classification for Unbalanced Aviation Communication Signals Based on Deterministic Oversampling[J]. Journal of Air Force Engineering University, 2025, 26(3): 18-25.

pectively, and compared to the traditional SMOTE method, the proposed method demonstrates still better performance in handling multi-class imbalance problems. And this method is enabled to effectively improve the accuracy in modulation signal classification in complex aeronautical communication environments, especially under complex electric-magnetic environments.

**Key words** signal modulation classification; multi-class imbalanced signal; oversampling; deterministic synthesis; data distribution

调制信号分类(简称为调制分类)是指区分接收到的射频信号所使用的调制方式<sup>[1]</sup>。在高速宽带航空通信领域,调制分类技术不仅能够帮助识别和优化信道选择,提升通信质量和速度,还能有效管理干扰,确保通信链路的可靠性<sup>[2]</sup>。随着航空器数量的快速增长和飞行环境的日益复杂,高速宽带航空通信技术面临着严峻的挑战,包括复杂电磁环境、快速多变的通信需求以及多样化的干扰源<sup>[3]</sup>。因此,提升通信质量和速度、管理干扰和保障通信链路的可靠性成为关键问题。此外,通过频谱管理和安全监测,调制分类能够提高频谱使用效率,防范非法信号,保障通信安全<sup>[4]</sup>。适应性通信和智能空中交通管理系统中的应用则进一步凸显了调制分类技术在不断变化的飞行环境中的重要性,其能够确保空中通信链路高效、稳定。

现有调制分类方法主要分为基于似然函数或人工选择特征的经典方法和基于深度学习的方法。在基于似然的方法中,调制分类被描述为假设检验问题。基于特征提取的方法则通常选择信号的循环谱<sup>[5]</sup>和高阶统计量<sup>[6]</sup>作为分类特征,对信号的调制方式进行分类。

深度学习具有端到端的学习特性,其适用于参数估计<sup>[7]</sup>、特征拟合、模式识别<sup>[8]</sup>、多类别分类<sup>[9]</sup>等问题。2016年,O'Shea等<sup>[10]</sup>通过深度学习实现了端到端的调制分类。史蕴豪等<sup>[11]</sup>将迁移学习应用到调制分类,有效提高了分类的准确性。Peng等<sup>[12]</sup>将复杂信号转换为例如图像等具有网格状拓扑的数据格式,并使用流行的深度学习网络模型和调制分类框架,取得了良好的效果。Bai等<sup>[13]</sup>提出了一种先验知识和对比特征相结合的调制分类方法,以先验知识为指导的特征提取可以准确地捕获调制信号中的关键模式,对比学习通过比较不同的样本来揭示各种调制模式之间的内在区别。Wang等<sup>[14]</sup>提出了一种用于信号调制分类的自动化机器学习框架,提出了可扩展的卷积随机傅立叶特征块,以有效提取调制特征,并给出了框架的初始搜索空间,将贝叶斯优化用于驱动超参数优化以实现调制

分类。

现有的调制分类方法大都是针对类平衡数据集的。在频谱管控和安全检测任务中,黑广播、假基站、干扰机等特定关注目标往往出现频率低、时间短,且信号源去向不确定,会导致此类目标的样本量往往较小。在这些情况下,调制信号数据集将变得不平衡。调制信号数据集的不均衡对基于机器学习和深度学习的调制分类方法均有一定的影响。对于基于机器学习的分类方法,当训练数据集不平衡时,模型会扩大多数类的决策范围,缩小少数类的决策范围,以寻求较低的损失函数值,从而导致偏差实际决策边界<sup>[15]</sup>。使得少数样本的预测精度被忽略。对于基于深度学习的分类方法,不平衡的数据会导致特征空间的扭曲,影响判别性特征的提取<sup>[16]</sup>。

基于确定性过采样技术<sup>[17]</sup>,本文提出了调制信号的确定性合成少数类过采样框架。对于不平衡的调制信号数据集,根据信号样本间的距离和分布合成新的样本。主要贡献如下:

1)针对不平衡调制信号提出了一种信号过采样的方法。由于合成信号样本仅基于训练集生成,因此过采样技术与要使用的分类器无关并且增加鲁棒性。该方法可以在不受分类器约束的情况下,提高均衡后调制分类任务的精度。

2)提出确定性地合成调制信号样本以平衡数据集。根据样本的分布和距离,确定性地合成调制信号样本,最大限度减少随机化对分类器生成方法的影响。

3)采用 RadioML 2016. 10a 数据集<sup>[18]</sup>,选取 5 个信噪比下 11 个不同类型的调制信号,设定了 4 个不平衡场景进行实验。结果表明,该方法在不同不平衡场景都能有效提高分类精度。

## 1 有关研究方法

### 1.1 调制分类方法

在经典调制分类方法中,Beidas 和 Weber 揭示了自相关函数与似然函数的关系,并建立了高阶相

关调制分类方法,推导了用信号高阶相关代替似然比进行 MFSK 调制分类的基本原理<sup>[19]</sup>。鲍丹等<sup>[20]</sup>将统计假设检验理论应用到调制分类中,提出了一种新的算法,该算法可有效地解决衰落信道下的 FSK 信号调制分类问题。

对于基于深度学习的调制分类方法,O'Shea 等<sup>[18]</sup>提出了用于信号调制分类的数据集 RadioML 2016.10a,并使用卷积神经网络(CNN)构建了端到端的网络模型<sup>[10]</sup>对调制信号进行分类,准确率为 87.4%。郭业才等<sup>[21]</sup>提出利用卷积神经网络对信号进行特征提取,用固定  $K$  均值算法对提取的特征进行聚类处理,实现对高低信噪比调制信号的准确分类。Wang 等<sup>[22]</sup>提出了一个少样本学习框架 MsmcNet 用于调制分类,实验结果表明其分类性能优于基线方法。Bai 等<sup>[23]</sup>提出了针对未标记调制信号的协作对比学习调制信号的协作对比学习(CoCL-Sig)。CoCL-Sig 获得的特征表示可以应用于调制信号以进行半监督分类和聚类任务。

## 1.2 数据过采样方法

过采样是通过一定的策略合成新的样本,并将其添加到原始数据集中的数据均衡化方法。在众多的过采样方法中,合成少数过采样技术(SMOTE)<sup>[24]</sup>是最广泛使用的方法之一。SMOTE 方法使用  $K$  近邻来寻找邻近的少数信号样本,并选择一个邻居在它们之间插入新的信号样本。这种合成少数类信号样本的过采样方法可以一定程度上降低过拟合的风险。Han 等<sup>[25]</sup>针对 SMOTE 算法易受噪声样本点影响的问题,提出了 Borderline-SMOTE 算法,该算法仅对靠近决策边界区域的正样本进行 SMOTE 采样,以减少噪声样本的影响。K-means-SMOTE<sup>[26]</sup>使用  $K$  均值聚类算法结合 SMOTE 过采样重新平衡数据集,仅在“安全区域”进行过采样以避免噪声。

## 1.3 研究问题及拟采用的方法

本文主要聚焦于航空通信中不平衡调制信号分类问题。调制信号在复杂电磁环境下,少数类信号样本的数量通常较少,导致现有的分类器在处理不平衡数据时,容易出现决策边界偏移或特征提取不充分的情况。传统的过采样方法虽然能够生成新的样本,但由于生成机制的随机性,合成样本的质量不高,难以完全解决分类器性能下降的问题。因此,如何确定性地生成高质量的少数类样本,提升分类器在不平衡场景下的性能,成为本文的核心研究问题。

针对上述问题,本文提出了一种基于确定性过

采样的调制信号分类方法。不同于传统的 SMOTE 算法,本文的方法通过分析样本间的分布和距离,确定性地合成少数类样本,避免了随机性带来的数据偏移问题。

## 2 面向不平衡信号的调制信号分类方法

过采样技术是一种可以解决调制信号不平衡问题的数据级方法,通过改变训练集的数据分布来降低不平衡程度。由于合成信号样本仅基于训练集生成,因此所使用的分类器与过采样技术无关。为了增加少数信号的数量并使少数类和多数类样本的数量相等,本文过采样技术平衡数据集以获得用于训练的样本集,并分别通过分类模型、信号幅度图和信号分布图来评估平衡数据。

### 2.1 方法建模

首先将不同类的调制信号输入,样本数最多的类被定义为多数类,其余为少数类。调制信号通常由  $I$  和  $Q$  正交信号组成,而这增加了信号的维度和复杂性。为了更有效地对原始信号进行过采样,该方法将  $I$  和  $Q$  2 路正交信号前后端到端连接,然后将它们输入到所提出的过采样方法中。

通过计算调制信号数据中少数类的分布,能够确定应从每个少数信号样本中生成合成信号样本数量以及生成方式。根据分布合成少数类信号样本,不仅可以确定性地生成合成样本,提高算法的鲁棒性,还可以控制少数类信号样本与合成信号样本在特征空间上的距离,进一步减少过拟合现象。信号平衡后,模型输出调制信号,恢复为  $I$  和  $Q$  正交信号,以评估过采样模型的有效性。

具体来说,对于输入调制信号中的少数类,将一一计算少数类中每个信号样本与其  $k$  最近邻之间距离的标准差,以获得每个信号样本周围的分布状态。然后根据样本信号样本周围分布的稀疏程度,计算每个信号样本周围要生成的信号样本的数量。信号样本将按照从稀疏到密集的顺序生成,分布越稀疏,需要生成的信号样本就越多。此外,根据每个信号样本与其  $k$  最近邻样本之间的距离,依次分配其  $k$  最近邻中的每个样本与目标信号样本之间的合成信号样本的数量。根据这个数字,在目标信号样本与其对应的邻居之间进行等间隔插值,以生成新的信号样本。通过这种方式,可以以确定并统一的方式创建合成信号样本。调制信号过采样及评估过程如图 1 所示。

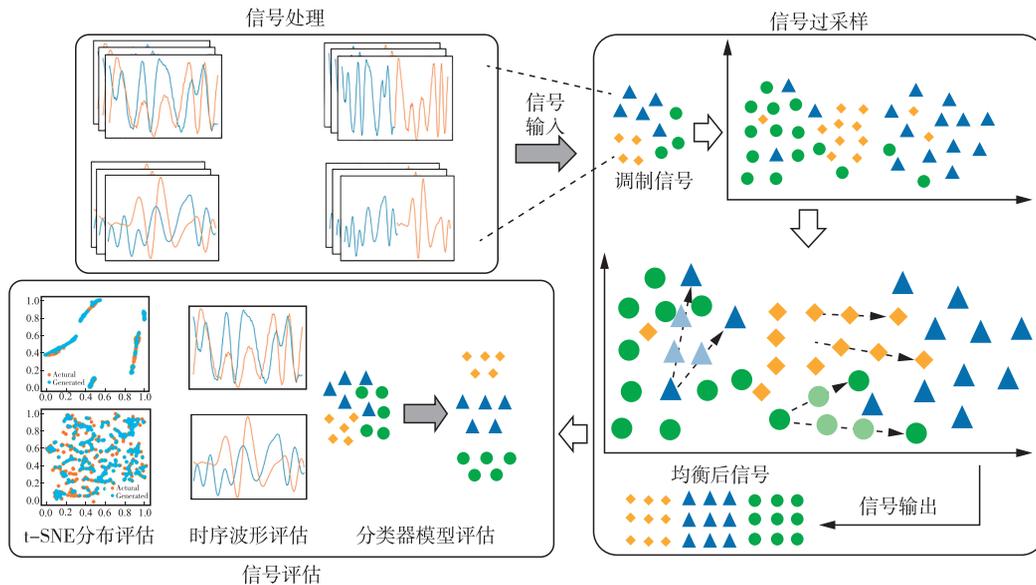


图 1 调制信号过采样及评估

Fig. 1 Oversampling of modulated signals and evaluation

## 2.2 合成信号样本数量的确定

通过计算对象  $i$  ( $\text{sample}_i$ ) 与其  $k$  最近邻之间距离的标准差  $\sigma_i$ , 可以得到少数类中每个对象  $i$  周围对象的分布。每个少数信号样本生成的合成信号样本的比率为:

$$r_i = \sigma_i / \sum_{i=1}^m \sigma_i \quad (1)$$

式中:  $m$  为每个少数类中的信号样本数。本方法将在少数类中的每个信号样本周围生成一定数量的合成信号样本。对于较高距离标准差的少数类信号样本将在周围生成更多信号样本, 在具有较低距离标准差的少数类信号样本周围生成较少信号样本。在决定了  $r_i$  后, 计算少数信号样本与其每个  $k$  近邻之间生成的合成信号样本的比率  $r_{ij}$ :

$$r_{ij} = d_{ij} / \sum_{j=1}^k d_{ij} \quad (2)$$

式中:  $r_{ij}$  由信号样本与每个最近邻之间的距离与信号样本与其所有  $k$  近邻之间的所有距离之和的比值计算得出。

## 2.3 合成方式的确定

对象  $i$  ( $\text{sample}_i$ ) 与其每个  $k$  近邻对象  $ij$  ( $\text{sample}_{ij}$ ) 之间生成的信号样本数量为:

$$s_{ij} = r_{ij} r_i n \quad (3)$$

式中:  $n$  为少数类产生的信号样本数, 其由少数类和多数类的信号样本数之差计算, 计算式为:

$$n = (M - m)R \quad (4)$$

式中:  $M$  为多数类中信号样本的数量;  $m$  为少数类中信号样本的数量;  $R$  为要实现的不平衡率的参数。需要指出的是, 需要生成的信号样本数  $s_{ij}$  应为整数, 故数据四舍五入并取整。统计每个对象  $i$

( $\text{sample}_i$ ) 与其最近邻对象  $ij$  ( $\text{sample}_{ij}$ ) 之间生成的合成信号样本的数量后, 计算对象  $i$  ( $\text{sample}_i$ ) 和对象  $ij$  ( $\text{sample}_{ij}$ ) 之间的属性差异:

$$\text{diff}'_{ij} = \text{diff}_{ij} / (s_{ij} + 1) \quad (5)$$

该方法将属性差异平均分为  $s_{ij}$  份, 然后在目标信号样本与其对应的邻居之间进行等距插值以生成新的信号样本:

$$\text{new\_sample}_{ijn} = \text{sample}_i + (\text{diff}'_{ij} \cdot n) \quad (6)$$

对于少数类中的信号样本, 如果计算出要生成的信号样本的数量小于一个信号样本, 则将不会从该信号样本生成信号样本。同样, 如果少数信号样本与某个最近邻信号样本之间要生成的信号样本的数量小于一个信号样本, 则不会生成新的信号样本。

## 3 不平衡调制信号分类实验

### 3.1 实验设置

#### 3.1.1 数据集

调制识别的测试数据集 RadioML 2016. 10a, 包含 8PSK、AM-DSB、AM-SSB、BPSK、CPFSK、GFSK、PAM4、QAM16、QAM64、QPSK、WBFM 等 11 类信号, 每类调制信号均包含信噪比为分布范围为 20~18 dB, 步进距离为 2 dB 的调制信号样本。数据集中模拟调制的数据源为 Serial Episode #1 的公开副本, 主要由带有一些插曲和关闭时间的原声语音组成。数字调制的数据源为整个古腾堡莎士比亚作品的 ASCII 格式, 并应用白化随机化器以确保符号和位等概率。

分别选择信噪比为 -8 dB、-4 dB、0 dB、4 dB、

8 dB 等 11 类调制信号,每一类信号的样本数量均为 1 000,随机选择 50% 的数据作为训练样本,另外 50% 的数据作为测试样本。通过在训练集中每类随机选取的数量不同模拟电磁信号不均衡的情况。

本文定义了 4 种不均衡情况,其中前 3 种不均衡情况分别选 3 个不同类作为少数类,其余类作为多数类;第 4 种情况则是把前 3 种情况中的少数类均作为少数类,其余为多数类,具体类别选择如表 1 所示。

表 1 不均衡情况中少数类

不均衡情况	1	2	3	4
少数类	8PSK	AM-SSB	QAM16	8PSK、AM-SSB、 QAM16

不同信噪比下的少数类数量均不相同,本文选定-8 dB 信噪比时少数类样本数量为 50,-4 dB 信噪比时样本数量为 100,0 dB 信噪比时样本数量为 150,4 dB 信噪比时样本数量为 150,8 dB 信噪比时样本数量为 250。

### 3.1.2 分类器和比较方法

采用了 3 种常用的深度学习网络模型 MsmcNet、ResNet50<sup>[27]</sup> 和 DenseNet121<sup>[28]</sup> 作为调制信号分类器。MsmcNet 是一种模块化少样本学习框架,专用于提高信号调制分类任务中的少样本分类性能;ResNet50 是一种由 50 层卷积层组成的深度残差网络,能够有效解决深度网络中的梯度消失问题;DenseNet121 通过密集连接所有前置层,增强特征复用,减少参数量,提升分类性能。为了验证本文提出方法的有效性,本文分别在上述 3 种模型上进行实验,并与传统的 SMOTE 方法进行比较。

### 3.2 不均衡调制分类实验结果定量分析

为了验证基于确定性合成少数类的电磁信号数据均衡化方法的效果,使用循环移位的传统方法进行数据的均衡化,并采用 MsmcNet 网络分类,循环移位方法采用 3 种不同的移位距离分别为信号样本长度的 25%、50% 和 75%,实验结果如表 2 所示。

表 2 循环移位均衡化并基于 MsmcNet 网络分类后结果对比  
Tab. 2 Comparison of classification results using cyclic shift equalization and the MS-MCNet network

方法	不均衡 情况 1	不均衡 情况 2	不均衡 情况 3	不均衡 情况 4
不均衡数据	63.48%	64.28%	65.93%	64.21%
循环移位 25%	64.83%	62.48%	64.85%	63.17%
循环移位 50%	63.28%	64.77%	64.13%	62.73%
循环移位 75%	64.74%	65.25%	64.87%	62.71%
本文方法	<b>66.26%</b>	<b>65.76%</b>	<b>66.27%</b>	<b>65.00%</b>

在所有不均衡情况中,本文方法的分类准确率均最高,循环移位技术的表现也较好,尤其是 50% 和 75% 的情况下,但总体来说本文方法的表现最佳。这表明了本文方法在处理不均衡数据上的有效性和鲁棒性,具有优势。

其次对比了不同数据均衡化方法对于同一深度学习分类器的性能提升情况。使用 SMOTE 和本文方法这 2 种生成式均衡方法生成少数类信号,并将均衡后的数据集使用 MsmcNet、ResNet50 和 DenseNet121 网络进行分类任务,实验结果如表 3~表 5 所示。

表 3 使用 MsmcNet 网络分类后结果对比

方法	不均衡 情况 1	不均衡 情况 2	不均衡 情况 3	不均衡 情况 4
不均衡数据	63.48%	64.28%	65.93%	64.21%
SMOTE	63.85%	65.72%	65.20%	62.49%
本文方法	<b>66.26%</b>	<b>65.76%</b>	<b>66.27%</b>	<b>65.00%</b>

表 4 使用 ResNet50 网络分类后结果对比

方法	不均衡 情况 1	不均衡 情况 2	不均衡 情况 3	不均衡 情况 4
不均衡数据	62.71%	61.54%	62.63%	59.85%
SMOTE	61.21%	61.55%	62.42%	58.22%
本文方法	<b>62.85%</b>	<b>62.12%</b>	<b>63.55%</b>	<b>60.16%</b>

表 5 使用 DenseNet121 网络分类后结果对比

方法	不均衡 情况 1	不均衡 情况 2	不均衡 情况 3	不均衡 情况 4
不均衡数据	60.10%	62.59%	61.21%	61.65%
SMOTE	62.43%	63.80%	63.64%	60.77%
本文方法	<b>63.55%</b>	<b>64.00%</b>	<b>64.30%</b>	<b>61.96%</b>

实验结果表明,本文提出的方法在处理数据不均衡问题时表现优异。与未均衡处理的数据和传统的 SMOTE 方法相比,本文方法在 3 种深度学习模型上的分类准确率均有显著提升,特别是在 MsmcNet 和 DenseNet121 上效果尤为明显。在不均衡数据集上,MsmcNet 和 DenseNet121 的分类准确率分别提高至 66.26% 和 64.30%,验证了该方法在电磁信号调制识别任务中的有效性和广泛适用性。

### 3.3 不均衡调制分类实验结果定性分析

由不同数据均衡化实验结果定量对比分析结果可以看到,所提出的基于确定性合成少数类的电磁信号数据均衡化对于不同分类器具有明显性能提

升,本节对于其生成样本进行波形可视化对比分析和生成数据分布可视化分析,以进一步验证其数据生成效果。

### 3.3.1 信号分布情况对比

为了直观地展示生成的信号与原始信号分布间的关系,验证信号生成的效果,将高维数据以可视的方式表示出来,同时,为了能够最大限度地保持内部结构关系,利用 t-SNE 将数据降至二维后绘制了相应的数据分布,如图 2 所示。

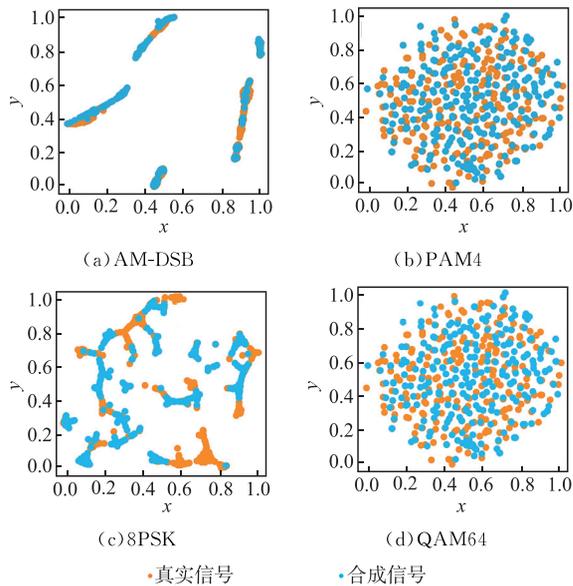


图 2 4 种信号可视化后分布对比

Fig. 2 Comparison of the distribution of results after visualizing four types of signals

图 2 中黄点为经 t-SNE 可视化后的真实信号,蓝点为生成的数据经 t-SNE 可视化后的合成信号。真实信号和合成信号在图中分布基本一致,说明合成信号在特征空间中能够较好地保持与真实信号的分布关系。对于 AM-DSB 和 8PSK 信号,合成信号与真实信号的重叠部分较多,表明文中所提方法在这些信号类型上能够有效地生成具有代表性的样本。对于 PAM4 和 QAM64 信号,虽然合成信号与真实信号存在一定的分布差异,但总体分布趋势仍较为一致。这说明文中所提方法在这些信号类型上仍具有一定的有效性,但需要进一步优化。

### 3.3.2 信号波形可视化对比

图 3 为 4 种典型的生成信号的对比结果。可以看出:对于 PAM4 信号,文中真实信号波形特点为相位相反,具体表现为 I 路和 Q 路信号大致呈现上下对称,而这个特点在合成信号波形中也有所体现;对于 QAM64 信号,文中真实信号波形特点为相位偏移, I 路相位比 Q 路超前大约  $2/\pi$ ,在合成信号波形中后半部分有所体现;对于 WBFM 和 GFSK 信号,文中两信号波形总体形状相似,特别是信号随时

间上升和下降时,部分波形存在一些相位对齐,尽管这在整个信号中并不完全一致。

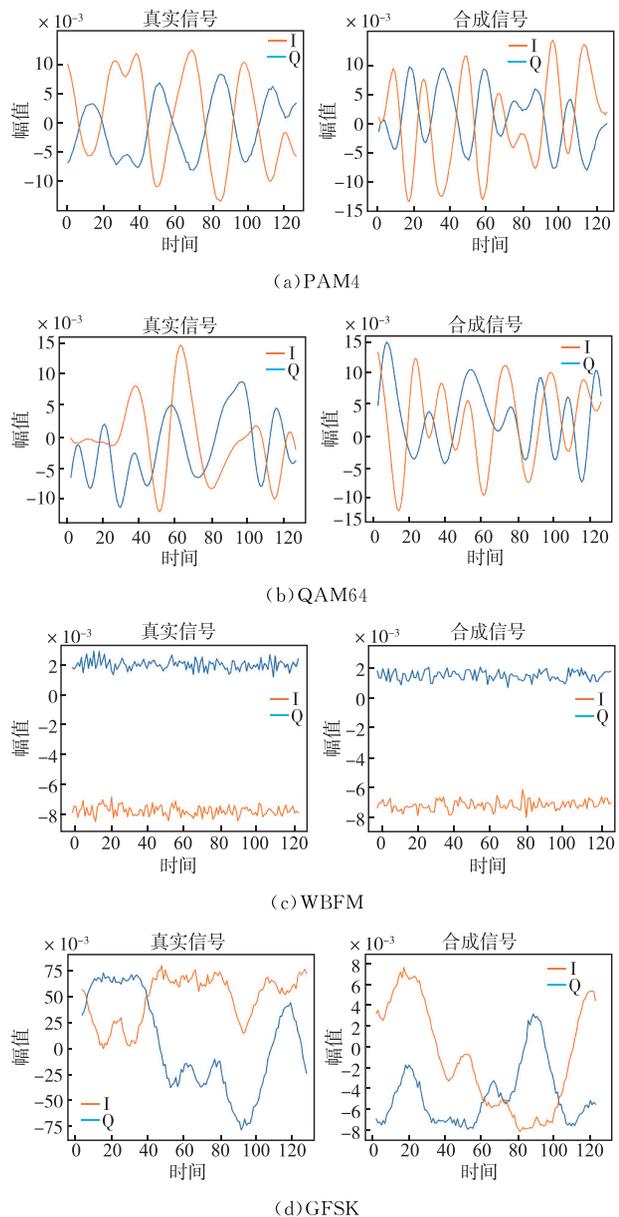


图 3 4 种典型信号的生成信号与真实信号对比

Fig. 3 Comparison of synthesized signals and real signals for four typical types of signals

## 4 结语

本文提出了面向不平衡信号的调制分类方法,该方法根据调制信号样本的分布和样本之间的距离,确定性地合成新的信号样本,以减少不平衡问题对分类器的影响。在实验部分,为了减少 SNR 和分类器的影响,分别在 MsmcNet、ResNet 和 DenseNet 3 个分类器下测试了 4 种不平衡情况的调制信号,并分析了合成信号与原始信号的波形和 t-SNE 分布的差异。结果表明,本方法在处理不平衡调制信号时更有效且具有更好的性能。

在未来的工作中,将尝试通过仿真多径、多普勒效应来增强现有数据集,使其更贴近实际航空通信信号的特性。通过处理不平衡的辐射源个体信号数据集,以将该方法应用于辐射源个体识别的任务。另外,对于调制信号的过采样方法,我们将探索更有效、更适用的方法。

## 参考文献

- [1] 杨晓飞. 边缘计算机下的调制信号分类算法与应用[D]. 济南:山东大学,2020.  
YANG X F. Algorithm and Application of Modulation Signal Classification Based on Edge Computing[D]. Jinan:Shandong University,2020. (in Chinese)
- [2] 元洪波,王珂. 航空信道下 MPSK 类信号的调制识别[J]. 信号处理,2013,29(2):249-255.  
YUAN H B, WANG K. Modulation Identification of MPSK Signals in the Aeronautical Channel[J]. Journal of Signal Processing, 2013, 29(2): 249-255. (in Chinese)
- [3] 贾鑫,蒋磊,郭京京,等. 基于深度聚类的通信辐射源个体识别方法[J]. 空军工程大学学报,2024,25(1):115-122.  
JIA X, JIANG L, GUO J J, et al. A Communication Emitter Identification Method Based on Deep Clustering[J]. Journal of Air Force Engineering University, 2024, 25(1): 115-122. (in Chinese)
- [4] BAI J, WANG Y R, XIAO Z, et al. RffAe-S: Autoencoder Based on Random Fourier Feature with Separable Loss for Unsupervised Signal Modulation Clustering[J]. IEEE Transactions on Industrial Informatics, 2022, 18(11): 7910-7919.
- [5] 赵春晖,杨伟超,马爽. 基于广义二阶循环统计量的通信信号调制识别研究[J]. 通信学报,2011,32(1):144-150.  
ZHAO C H, YANG W C, MA S. Research on Communication Signal Modulation Recognition Based on the Generalized Second-Order Cyclic Statistics[J]. Journal on Communications, 2011, 32(1): 144-150. (in Chinese)
- [6] 王彬,葛临东. 一种基于高阶矩的 OFDM 信号调制盲识别算法[J]. 数据采集与处理,2006,21(1):37-41.  
WANG B, GE L D. Algorithm for Blind Identification of OFDM Signal Based on Higher Order Moments[J]. Journal of Data Acquisition & Processing, 2006, 21(1): 37-41. (in Chinese)
- [7] 郭书涵,胡国平,赵方正,等. 基于深度卷积神经网络的 DOA 估计[J]. 空军工程大学学报,2023,24(4):62-68.  
GUO S H, HU G P, ZHAO F Z, et al. A DOA Estimation Based on Deep Convolutional Neural Network[J]. Journal of Air Force Engineering University, 2023, 24(4): 62-68. (in Chinese)
- [8] 李鹏,冯存前,胡晓伟. 一种改进的可解释 SAR 图像识别网络[J]. 空军工程大学学报,2023,24(4):49-55.  
LI P, FENG C Q, HU X W. An Improved Interpretable SAR Image Recognition Network[J]. Journal of Air Force Engineering University, 2023, 24(4): 49-55. (in Chinese)
- [9] 闫云飞,孙鹏,张杰勇,等. 基于领域 BERT 模型的服务文本分类方法[J]. 空军工程大学学报,2023,24(1):103-111.  
YAN Y F, SUN P, ZHANG J Y, et al. A Service Text Classification Method Based on Domain BERT Model[J]. Journal of Air Force Engineering University, 2023, 24(1): 103-111. (in Chinese)
- [10] O'SHEA T J, CORGAN J, CLANCY T C. Convolutional Radio Modulation Recognition Networks[C]//Engineering Applications of Neural Networks. Cham: Springer International Publishing, 2016: 213-226.
- [11] 史蕴豪,许华,单俊杰. 基于域适应神经网络的调制方式分类方法[J]. 空军工程大学学报(自然科学版),2020,21(5):69-75.  
SHI Y H, XU H, SHAN J J. A Modulation Recognition Method Based on Domain Adaptive Neural Network[J]. Journal of Air Force Engineering University (Natural Science Edition), 2020, 21(5): 69-75. (in Chinese)
- [12] PENG S L, JIANG H Y, WANG H X, et al. Modulation Classification Based on Signal Constellation Diagrams and Deep Learning[J]. IEEE Transactions on Neural Networks and Learning Systems, 2019, 30(3): 718-727.
- [13] BAI J, LIU X B, WANG Y R, et al. Integrating Prior Knowledge and Contrast Feature for Signal Modulation Classification[J]. IEEE Internet of Things Journal, 2024, 11(12): 21461-21473.
- [14] WANG Y R, BAI J, XIAO Z, et al. AutoSMC: An Automated Machine Learning Framework for Signal Modulation Classification[J]. IEEE Transactions on Information Forensics and Security, 2024, 19: 6225-6236.
- [15] DAS S, MULLICK S S, ZELINKA I. On Supervised Class-Imbalanced Learning: An Updated Perspective and Some Key Challenges[J]. IEEE Transactions on Artificial Intelligence, 2022, 3(6): 973-993.
- [16] LIU J L, SUN Y F, HAN C C, et al. Deep Representation Learning on Long-Tailed Data: A Learnable Embedding Augmentation Perspective[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA: IEEE, 2020: 2967-2976.

- [17] TORRES F R, CARRASCO-OCHOA J A, MARTÍNEZ-TRINIDAD J F. SMOTE-D a Deterministic Version of SMOTE[C]//Pattern Recognition. Cham: Springer International Publishing, 2016: 177-188.
- [18] O'SHEA T J, WEST N. Radio Machine Learning Dataset Generation with GNU Radio[C]// Proceedings of the GNU Radio Conference. 2016.
- [19] 罗利春. 高阶相关调制分类原理、判决门限与仿真研究[J]. 系统工程与电子技术, 2002, 24(12): 25-29, 39. LUO L C. Principles, Decision Threshold and Experiment Performance of Higher-Order Correlation Based Modulation Classification [J]. Systems Engineering and Electronics, 2002, 24(12): 25-29, 39. (in Chinese)
- [20] 鲍丹, 杨绍全, 崔艳鹏. 瑞利衰落信道下 FSK 信号的调制分类[J]. 西安电子科技大学学报, 2006, 33(1): 98-102. BAO D, YANG S Q, CUI Y P. Classification of the FSK Signal over a Rayleigh Fading Channel[J]. Journal of Xidian University, 2006, 33(1): 98-102. (in Chinese)
- [21] 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. (in Chinese)
- [22] WANG Y R, BAI J, XIAO Z, et al. MsmcNet: A Modular Few-Shot Learning Framework for Signal Modulation Classification[J]. IEEE Transactions on Signal Processing, 2022, 70: 3789-3801.
- [23] BAI J, WANG X, XIAO Z, et al. Achieving Efficient Feature Representation for Modulation Signal: A Cooperative Contrast Learning Approach[J]. IEEE Internet of Things Journal, 2024, 11(9): 16196-16211.
- [24] CHAWLA N V, BOWYER K W, HALL L O, et al. SMOTE: Synthetic Minority Over-Sampling Technique[J]. Journal of Artificial Intelligence Research, 2002, 16: 321-357.
- [25] HAN H, WANG W Y, MAO B H. Borderline-SMOTE: A New Over-Sampling Method in Imbalanced Data Sets Learning[M]//Advances in Intelligent Computing. Berlin, Heidelberg: Springer, 2005: 878-887.
- [26] DAS S, MULLICK S S, ZELINKA I. On Supervised Class-Imbalanced Learning: An Updated Perspective and Some Key Challenges[J]. IEEE Transactions on Artificial Intelligence, 2022, 3(6): 973-993.
- [27] HE K M, ZHANG X Y, REN S Q, et al. Deep Residual Learning for Image Recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV: IEEE, 2016: 770-778.
- [28] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely Connected Convolutional Networks [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI: IEEE, 2017: 2261-2269.

(编辑:徐楠楠)