

基于生成对抗网络的无线电数据增扩与分类

张凤荔¹, 周志远¹, 王瑞锦^{1*}, 黄鑫¹, 韩英军²

¹ 电子科技大学信息与软件工程学院 成都 中国 610054

² 四川中烟工业有限责任公司成都卷烟厂 成都 中国 610066

摘要 相较于传统的无线电数据特征提取方法, 深度学习具有高效灵活的特点, 其可以有效提高调制数据识别的性能。然而在实践中, 收集大量可靠的无线电调制样本数据有时代价是昂贵和困难的, 这在很大程度上限制了深度学习模型的性能。本文提出了基于生成对抗网络(Generative Adversarial Networks, GAN)的无线电调制数据增扩模型 RMAbGAN(Radio Modulation data Augmentation based on Generative Adversarial Networks), 该模型通过挖掘不同信噪比与调制方式下的无线电调制数据特征差异, 生成符合调制方式与信噪比特点的无线电调制数据, 模型中的生成器部分捕获无线电调制数据分布特征, 判别器部分优化生成器性能, 两者相互博弈性能不断提升; 在此基础上, 对无线电数据采样特点与无线电数据传统增强方法进行深度分析与研究, 发现了无线电调制数据蕴含的空域特征与时序特征, 设计出了能深刻捕获无线电数据空域特征与时序特征的无线电数据分类模型 AMCST(Automatic Modulation Classification based Spatial and Temporal feature)。通过大量的对比实验, 表明相较于基于旋转变换的无线电调制数据增扩模型, RMAbGAN 模型在无线电调制数据增扩方面更具有鲁棒性和泛化能力, 可以实现更高的调制分类准确率。此外, 相较于基于长短期记忆网络(Long Short-Term Memory, LSTM)的调制分类模型、基于残差网络(Residual Networks, ResNet)的调制分类模型等传统模型, AMCST 模型在调制数据分类方面更具有稳定性和可用性, 同时也具有更高的分类准确率。

关键词 无线电调制数据增扩; 无线电调制数据分类; 生成对抗网络; 卷积神经网络; 循环神经网络

中图分类号 TP183 DOI号 10.19363/J.cnki.cn10-1380/tn.2023.09.04

Radio Data Augmentation with GAN for Automatic Modulation Classification

ZHANG Fengli¹, ZHOU Zhiyuan¹, WANG Ruijin^{1*}, HUANG Xin¹, HAN Yingjun²

¹ School of Information and Software Engineering, University of Electronic Science and Technology of China, Chengdu 610054, China

² Sichuan China Tobacco Industry Co., Ltd. Chengdu Cigarette Factory, Chengdu 610066, China

Abstract Compared with traditional radio modulation data feature extraction methods, deep learning is more efficient and flexible. So it can effectively improve radio modulation data recognition performance. However, in practice, it is too costly and difficult to collect a vast number of reliable radio modulation data samples that the performance of deep learning models is limited largely. In this paper, we propose a radio modulation data augmentation model named RMAbGAN (Radio Modulation data Augmentation based on Generative Adversarial Networks) based on generative adversarial networks. It can generate the radio modulation data satisfying the characteristics of SNR(Signal Noise Ratio) and modulation type by mining the characteristic differences of radio modulation data under different SNR and modulation types. In our model, the generator captures the distribution characteristics of radio modulation data samples and the discriminator optimizes the generator's performance and parameters. The performance of the model will continue to improve by learning the generator and discriminator in the process of playing against each other. By the way of deep analyzing and researching radio data sampling methods and traditional radio data enhancement methods, we discover the spatial and temporal features in radio modulation data. According to these potential features, we present a radio modulation data classification model named AMCST (Automatic Modulation Classification based Spatial and Temporal feature) that is able to capture as many potential spatial and temporal attributes as possible in radio modulation data. Through a large number of comparative experiments, it is found that RMAbGAN model has better robustness and generalization ability compared with the radio modulation data enhancement model based on rotation transformation, and can achieve higher accuracy of radio modulation classification. In addition, compared with the traditional radio modulation classification model based on long short-term memory and residual networks, AMCST is so available and stable

通讯作者: 王瑞锦, 博士, 副教授, ruijinwang@uestc.edu.cn

基金项目: 国家自然科学基金(No. 61802033, No. 61472064, No. 61602096)、四川省区域创新合作项目(No. 2020YFQ0018)、四川省科技计划重点研发项目(No. 2020YFG0475, No. 2018GZ0087, No. 2019YJ0543)、博士后基金项目(No. 2018M643453)、广东省国家重点实验室项目(No. 2017B030314131)、网络与数据安全四川省重点实验室开放课题(No. NDSMS201606)资助。

收稿日期: 2021-12-22; 修改日期: 2022-05-27; 定稿日期: 2023-06-12

that can improve classification accuracy.

Key words radio modulation data enhancement; radio modulation data classification; generative adversarial networks; convolutional neural networks; recurrent neural networks

1 引言

在无线通信领域,稀缺且即将耗尽的频谱资源^[1]以及已分配但未充分利用的频谱资源使用现状推动了人们在认知无线电领域^[2]的研究。无线电调制数据识别作为认知无线电领域不可或缺的重要组成部分,其可以正确识别无线调制数据的调制类别,为数据解调、内容提取等后续工作提供保障,进而提高无线信道利用率,使无线信道的数据传输更加可靠与稳定。因此,如何提高无线电调制数据分类准确率,吸引了众多研究学者的目光。

从传统依靠专业通信人员的经验识别无线电数据调制方式^[3],到使用如带宽、频率等特征参数的调制方式识别,再到利用以小波变换、循环谱为代表的多特征融合的调制方式自动识别,关于无线电调制方式的自动识别人们已经取得了良好的成绩。但这些算法往往包含复杂的无线电数据多特征提取与多特征融合,并且在信噪比较低情况下不能获得较理想的调制分类识别率^[4]。

随着深度学习^[5]在语音识别^[6]、机器翻译^[7]等领域日益广泛的应用与深入。近年来,诸多学者热衷于将深度学习技术引入到无线电调制数据的识别领域。相比于传统的无线电调制数据识别,基于深度学习的调制识别算法在数据特征提取方面具有学习能力强、覆盖范围广及适应性好的特点,可以通过优化参数获取更好的模型性能。关于无线电调制数据的分类算法研究,诸多研究学者简单地将卷积神经网络^[8](Convolutional Neural Networks, CNN)与长短期记忆网络^[9]等深度学习模型引入到无线电调制数据分类识别算法中,这样可以提高无线电调制数据分类的性能。然而其未充分综合考虑无线电数据采样特点,无法实现同时对无线电调制数据空域特征与时序特征的捕获,且此类方法需要大量的无线电调制样本数据,这极大的限制了调制数据分类模型的性能。

虽然基于深度学习的方法可以有效提高无线电调制数据分类的性能,但它需要大量的无线电调制样本数据,此外无线电调制数据的质量也会影响调制分类模型的性能。在实践中,收集大量可靠的无线电调制样本数据有时代价是昂贵和困难的,这吸引了众多学者将目光投向无线电调制数据领域的增

扩。关于无线电调制数据的增扩,研究学者主要通过以下两种方式完成:①将传统的图片数据、文本数据等内容数据的增扩方式迁移至无线电调制数据增扩领域;②充分利用变分自编码器、生成对抗网络及其变种等方式实现无线电调制数据的增扩。但多种类别调制数据的特征分布差异给提高这类模型的性能带来了挑战。

针对上述问题,我们提出了基于生成对抗网络的无线电调制数据增扩模型 RMAbGAN,生成与原始数据分布特征相同的“伪造”数据,达到对原始数据集增扩的目的;此外,基于无线电数据采样特点,提出了深刻捕获无线电数据空域特征与时域特征的调制分类模型 AMCST,提高无线电调制数据分类准确率。

本文的主要贡献总结如下:

(1) 创新设计了针对无线电调制数据的增扩模型——基于生成对抗网络的无线电调制数据增扩模型 RMAbGAN,其中生成器捕获无线电调制数据分布特征,辨识器优化生成器性能,最终利用生成器生成符合原始无线电数据特点的增扩无线电数据。

(2) 结合无线电调制数据本身特征,设计了可以挖掘不同信噪比与调制方式下无线电调制数据特征差异的深度生成器网络与深度辨识器网络,生成符合调制方式与信噪比特点的无线电调制数据。

(3) 分析与研究了无线电数据采样特点与无线电数据传统增强方式,发现了无线电调制数据蕴含的空域特征与时序特征,设计了能深刻捕获无线电数据空域特征与时序特征的无线电数据分类模型 AMCST。

(4) 利用公共数据集,验证了数据增扩方法在无线电调制数据生成方面与调制分类方法在无线电数据调制识别方面的有效性,提高了无线电调制信号的分类精度,为频谱异常检测、发射机识别与频谱感知等领域的研究提供支持。

2 相关工作

2.1 数据增强

数据增强在深度学习领域得到了广泛的应用,其主要用于扩充原始数据集,使数据更加多样,防止模型过拟合,降低模型敏感度,提高模型鲁棒性,实现在不增加数据采样代价的情况下,让小规模数

据集产生与较大规模数据集等同的数据价值。

针对图像分类任务,为克服小数据集的弊端,使图像数据集更充实,按照是否使用标签监督模型训练,可以分为有监督和无监督两类图像数据增强方法^[10]。有监督的数据增强包含单样本数据增强和多样本数据增强,生成新的样本数据和学习增强策略是无监督的数据增强的两个重要研究分支。

关于有监督的单样本数据增强方法,研究者通常采用几何变换与颜色变换两种方式实现对图片数据集的增扩,从而提高分类模型准确率。几何变换常用翻转、旋转、裁剪、缩放、移位等方法来增扩数据集^[11],翻转和旋转都是将原始的图像像素在位置空间上做变换,图像的翻转是对原始的图像做镜像操作,图像的旋转是将图像沿中心做任意角度的旋转变换,移位将图像沿 X 轴或者 Y 轴移动图像达到增强目的。颜色变换常用噪声、模糊、随机擦除、色彩抖动、以及超像素法实现图像数据的增扩。模糊通过减少各像素点值的差异实现像素的平滑化,其中最简单且常见的是高斯模糊。超像素法在图像的最大分辨率处生成若干超像素,并将图像重新调整为原始大小,再以概率 p 用所生成的超像素替换原始图像中超像素区域的数据,其他区域像素值不变。图片往往具备亮度、饱和度和对比度等参数,色彩抖动通过调整这些参数实现图像数据的增强。噪声增强是在原始图像数据的基础上随机增加一些随机噪声。有监督的多样本数据增强方法利用多个样本来产生新的样本。SMOTE^[12](Synthetic Minority Over-sampling Technique)对少数类样本进行分析,使用插值法根据少数类样本人工合成新样本,解决样本数据不平衡的问题,实现数据增强。SamplePairing^[13]从训练集中随机抽取两张图片取两者像素平均值的叠加合成一个新的样本,标签为所选样本图片标签中的一种,其在医学图像数据增强方面取得了不错的成效。mixup^[14]是以线性插值的方法生成新的样本数据与样本标签,最小化了邻域风险,有助于消除模型训练过程中的不稳定性。

无监督的数据增强方法包括两类:①通过数据生成模型学习原始数据集中的数据分布特征,之后利用生成模型生成与训练数据集分布特征一致的样本数据,典型代表方法有 GAN^[15]等;②使用搜索模型寻找最适合当前场景的数据增强方法,其典型代表有 AutoAugment^[16]等。

相较于图像数据多样的数据增扩方法,文本数据的增扩方法较为单一,其核心思想主要是通过生成“同义句”的方法实现文本数据的增扩,Wei J^[17]等

人使用同义词替换、随机插入、随机交换和随机删除等操作扩充原始文本数据集。随机插入是在同义词集合中随机选择一个字符插入原文本中。随机交换数据增强是基于给定的文本随机交换其中的两个词。

不同于图像与文本数据,音频数据可从时域角度与空域角度出发实现音频数据的增扩。从音频时域角度看,音频时域波形具有音调、响度与质量等特征,可通过加入噪声、增加混响、调整音量等方式实现数据增强。从频域的角度,Ko T^[18]等人通过改变音频速度、扭曲特征、屏蔽音频通道块等方式达到对音频数据增强的目的。

在无线电调制数据增扩领域,Huang L^[19]等人将无线电调制数据视为“图片”并按照上述图片数据的增强方法进行数据增强,从而实现无线电调制数据增强,并取得了不错的调制分类效果,且证明了无线电调制数据存在空域特征信息。Mansi Patel^[20]提出了一种基于条件生成对抗网络的数据生成模型,生成器与辨识器采用全连接网络实现无线电调制数据的生成与数据特征的提取,但是真实场景下无线电调制数据的标签信息往往是难以获取的,这也给基于条件生成对抗网络的无线电调制数据增扩带来了挑战。以上无线电调制数据的增扩方式,均未考虑无线电调制数据本身的分布特征和不同调制类别数据的分布差异。

2.2 无线电调制数据分类

分类问题是日常业务问题的重要组成部分,吸引了众多学者的目光。分类算法研究作为数据挖掘、机器学习与模式识别中的一个重要领域,目前已经形成诸多经典的分类算法,并在实际的分类任务中取得了不错的效果,这就包括逻辑回归(Logistic Regression, LR)、支持向量机^[21](Support Vector Machine, SVM)、K 近邻算法^[22](k-Nearest Neighbor, KNN)、朴素贝叶斯^[23](Naive Bayesian Model, NBM)与分类树等算法。伴随着机器学习的发展,以深度学习为核心的分类算法的应用领域日益广泛,也日益受到研究学者的关注。

在无线电调制数据的分类领域,出于无线电数据的采样特点与深度学习特征提取的优势,诸多研究学者研究并提出了基于深度学习的无线电调制数据分类算法。O'Shea^[24]等人将卷积神经网络与全连接网络相结合实现无线电数据特征提取与数据分类。基于对调制数据采样特点的研究,Huang L^[19]等人使用 LSTM 结构与全连接网络进行无线电调制数据分类,其中 LSTM 结构可充分捕获无线电调制数

据的时序特性。随着残差网络在各个应用场景的使用, Huynh^[25]等人提出了基于残差网络的无线电调制数据识别模型, 其核心由 Pre-block、M-block 与 M-block(p)组成。李佳宸^[4]等人将无线电数据特征提取分为原始特征提取与深层特征提取, 原始特征提取主要利用循环谱变换或者小波变换, 数据深层特征提取利用深度神经网络获得, 最后将上述特征信息输入定制分类器实现对无线调制数据分类。S. Peng^[26]等人将两个经典的神经网络模型 GoogleNet 和 AlexNet 从传统的图像识别领域迁移至无线电调制数据的分类。S. Rajendran^[27]等人充分考虑调制数据的时域、振幅和相位信息, 将长短期记忆网络引入到数据分类模型中, 实现了较高的数据分类准确率。Ramjee S^[28]等人研究不同信号的采样方式, 减少输入数据维度, 达到了减少训练时间的目的。综上, 这些调制分类算法未同时综合考虑无线电调制数据中所蕴藏的空域特征信息与时序特征信息。

3 概念及问题定义

本文使用到的具体表示符号与运算符号汇总于表 1 中。

表 1 主要符号说明表
Table 1 Principal symbols definition

符号	说明
M	原始无线电调制数据
F	调制数据增扩模型生成的伪造数据
S	无线电调制数据增扩规模
X	无线电增扩数据集
ψ	无线电调制数据到调制类别的映射函数
C	无线电数据调制类别
SNR	无线电调制数据信噪比
$ \cdot $	数据量计算
G	生成对抗网络中的生成器
D	生成对抗网络中的辨识器
\otimes	卷积神经网络卷积操作
\odot	逐项乘积操作
\parallel	向量拼接操作
I	同相位信号
Q	正交相位信号

3.1 信号调制

为满足在距离较远的两个端点之间的数据传输, 往往需要将信号从低频转换到高频, 使信号数据可以在信道中正确传输, 这个过程称之为调制^[29]。根据信号表示方式的不同, 信号可以分为具有连续特点的模拟信号与具有离散特点的数字信号, 其相应的

调制方式是模拟信号调制与数字信号调制^[30]。信号具有振幅、频率、相位三个要素, 根据三个要素的不同, 模拟信号的调制又可以分为幅度调制 (Amplitude Modulation, AM)、频率调制 (Frequency Modulation, FM) 与相位调制 (Phase Modulation, PM)。数字信息具有离散的特点, 可以使用数字信息对开关进行调控, 这也就是键控。关于数字信号调制, 依据上述信号的三个要素, 可以分别使用振幅键控^[31] (Amplitude Shift Keying, ASK)、频移键控 (Frequency Shift Keying, FSK) 和相移键控^[32] (Phase Shift Keying, PSK) 实现对数字信号的调制^[33]。随着时代的发展与技术的变革, 数字信号调制技术也进行了相应的改进与调整, 先后涌现出如正交振幅调制 (Quadrature Amplitude Modulation, QAM) 和最小频移键控 (Minimum Shift Keying, MSK) 等现代调制技术。常见的信号调制方法如表 2 所示。

表 2 常见信号调制类别汇总表
Table 2 The Summary of ordinary signal modulation categories

信号类别	常见调制方式
模拟信号	幅度调制 AM
	频率调制 FM
	相位调制 PM
数字信号	振幅键控 ASK
	频移键控 FSK
	相移键控 PSK
	正交振幅调制 QAM
	最小频移键控 MSK

3.2 问题定义

数据增扩是指基于给定的原始无线电调制数据 M , 设计生成对抗网络模型深刻捕获数据分布特征, 生成“伪造”数据 F , 并按照指定的增扩规模 S 完成对原始数据集 M 的增扩, 获取增扩数据集 $X = \{M, F\}$ 。

无线电调制分类是为获取从无线电调制数据 $x \in X$ 到不同调制类别 C 的映射 ψ 。分类结果 $\psi(x)$ 中的概率最大值所对应的类别即为待估计样本数据 x 的估计调制类别。

3.3 方法概述

为实现对原始无线电调制数据集的增强扩充, 设计了基于生成对抗网络的调制数据增扩模型 RMAbGAN; 为深刻捕获无线电增扩数据空域特征与时序特征, 提出了无线电调制数据分类模型 AMCST。

(1) 调制数据增扩模型RMAbGAN

设原始数据集中信噪比 SNR 为 snr 与无线电调制类型 C 为 c 的情况下无线电调制数据为 $M^{(snr,c)} = \{M_i^{(snr,c)}, i \in (1, 2, \dots, n)\}$, $M_i^{(snr,c)} \in \mathbb{R}^{k \times |V|}$, 其中 k 表示无线电调制数据的通道数量, $|V|$ 表示无线电调制数据的采样次数。数据增扩是利用生成对抗网络生成伪造数据 $F^{(snr,c)}$, 将伪造数据 $F^{(snr,c)}$ 与真实数据 $M^{(snr,c)}$ 混合实现对本类别调制数据的增扩,

其中 $\frac{|F^{(snr,c)}|}{|M^{(snr,c)}|} = S$, 此处的 $||$ 运算表示获取输入数据

集的数量。调整信噪比 SNR 与调制类型 C 的值, 将选择的无线电调制数据放入数据增扩模型, 实现选择数据的增扩, 最终得到所有调制类别数据的增扩, 即 $X = \{M, F\}$ 表示原始数据集与增扩数据集的聚合。

(2) 调制数据分类模型AMCST

无线电信号调制分类问题可以被看作是从无线电调制数据到不同调制类别的映射。分类结果中的概率最大值所对应的类别即为待估计样本数据的估计调制类别。

我们设计的无线电调制分类模型AMCST, 以增扩数据 $x \in X$ 为输入, 经调制分类模型 ψ 得到分类结果 $\psi(x) \in \mathbb{R}^{|C|}$, 其中 $|C|$ 表示无线电调制数据的类别数。从 $\psi(x)$ 中选择出最大数值所对应的调制类别即为调制分类模型 ψ 对输入数据 x 的预测调制类别。

4 模型设计

基于生成对抗网络的无线电数据增扩与分类模型整体结构如图 1 所示。整个模型包括两大部分, 第一部分是调制数据增扩, 出于无线电调制数据样本数量与质量影响基于深度学习的调制数据分类模型性能的客观事实, 提出了一种基于生成对抗网络的无线电调制数据增扩模型 RMAbGAN; 第二部分是调制数据分类, 基于无线电数据采样特点, 为充分捕获无线电调制数据空域特征与时序特征, 设计了由 CNN 与 LSTM 构建的无线电调制数据分类模型 AMCST。

4.1 调制数据增扩模型 RMAbGAN

为生成符合调制方式与信噪比特点的无线电调制数据, 调制数据增扩模型 RMAbGAN 以随机噪声与某类别调制数据为输入, 利用生成对抗网络的生成器捕获此类别数据分布特征, 生成判别器难以区分的“伪造”数据, 且尽可能保证其与本类别数据分

布特征相同, 达到对原始无线电调制数据集增扩的目的^[34]。




图 1 模型概览图

Figure 1 The overview of our model




图 2 RMAbGAN 的网络模型结构图

Figure 2 The architecture of the model RMAbGAN

调制数据增扩的生成对抗网络结构如图 2 所示, 其由生成器 G 和判别器 D 两部分组成, 整体目标函数表达式 $V(D, G)$ 如下公式(1)所示:

$$\min_G \max_D V(D, G) = E_{m \sim P_{data}(m)} [\log(D(m))] + E_{z \sim P_z(z)} [\log(1 - D(z))] \quad (1)$$

该结构包括两个神经网络模型: 一个是生成器 G , 其通常以服从随机分布 P_z 的数据 z 作为输入来生成“伪造”数据 $G(z)$, 并且尽可能保证 $G(z)$ 服从于真实数据分布 P_{data} ; 另一个是判别器 D , 其通常以真实数据 m 与生成的“伪造”数据 $G(z)$ 为输入, 用来估计输入数据来自真实数据集 M 而不是生成器生成的“伪造”数据 $G(z)$ 的概率。生成器 G 的目标是使判别器 D 不能正确区分自己生成的“伪造”数据 $G(z)$ 和真实数据 m (即使 $D(G(z))$ 与 $D(m)$ 尽可能保持一致), 生成器 G 与判别器 D 两个模型相互对抗, 判别器 D 辨识数据来源的性能不断提升, 生成器 G 为了成功欺骗判别器, 其生成数据的质量也逐渐趋近于真实数据分布 P_{data} , 最终生成器 G 可以学到真实数据的分布^[35]。此时, 将随机噪声输入生成器 G 便可以生成近似于真实数据分布 P_{data} 的“伪造”数据, 实现对无线电调制数据的增扩。

针对不同调制方式与信噪比无线电调制数据特征分布差异, 我们设计的生成器模型如图 3(a)所示。其由六个全连接层组成, 依次包含 1 个 128 个神经元的全连接层、3 个 256 个神经元的全连接层、1 个 512

个神经元的全连接层。其中 Leaky ReLU 函数与 Batch Normalization 函数作为各全连接层的激活函数与归一化处理函数。设计的辨识器模型如图 3 (b)所示。其同样由 6 个全连接层组成, 前 5 个全连接层每层有 512 个神经元, 最后一层仅包含 1 个神经元用来确定输入无线电调制数据的真假(为真表示输入数据来源于原始调制数据集, 为假表示输入数据来源于生成器生成的“伪造”调制数据), 最后一层全连接层的激活函数使用 Sigmoid 函数。




图 3 调制数据增扩模型 RMAbGAN
Figure 3 The details of RMAbGAN

算法: 基于生成对抗网络的无线电调制数据增扩模型 RMAbGAN

输入: 真实无线电调制数据 $M^{(snr,c)}$

输出: 增扩模型生成的“伪造”数据 $F^{(snr,c)}$

1. for epoch in range(epoches):
2. /*固定辨识器 D , 训练生成器 G */
3. 采样噪声数据 z , z 服从随机分布 P_z
4. $F^{(snr,c)} \leftarrow$ 生成器生成伪造数据 $G(z)$
5. $g_loss \leftarrow$ 依据辨识器 D , 计算生成伪造数据 $F^{(snr,c)}$ 损失
6. 更新损失 g_loss
7. /*固定生成器 G , 训练辨识器 D */
8. $d_loss \leftarrow$ 依据辨识器 D , 计算生成伪造数

据 $F^{(snr,c)}$ 与真实调制数据 $M^{(snr,c)}$ 的损失和

9. 更新损失 d_loss

10. 利用生成器 G 生成伪造无线电调制数据 $F^{(snr,c)}$

4.2 调制数据分类模型 AMCST

无线电调制数据来源于每个仿真源输出流的随机采样时间段, 其具备时序特性。为综合考虑无线电数据空域特征与时序特征, 我们使用 CNN 模型与 LSTM 模型构建调制分类模型 AMCST, 如图 4 所示。AMCST 模型包括三部分: CNN 子结构、LSTM 子结构和子结构混合。其中 CNN 子结构用于捕获无线电调制数据空域特征信息, LSTM 子结构用于捕获无线电调制数据时序特征信息, 子结构混合模块将前述两个子模块结果汇合, 综合度量空域特征信息与时序特征信息得到输入样本数据的预测调制分类结果。

设无线电调制数据为 $x \in X$, x 的第 j 个元素是 x_j 。

(1) 无线电数据空域特征提取—CNN 子结构

CNN 与传统多层感知机(Multilayer Perceptron, MLP)相比, 使用了节点部分连接的卷积层与池化层, 减少了整个模型中的可训练参数, 降低了模型过拟合风险, 使得模型在新鲜样本上具有更好的泛化性能^[36]。CNN 可以更好的挖掘存在于数据中强烈的局部空间相关性, 因此, 使用 CNN 捕获无线电调制数据的空域特征。

CNN 的前向计算方式定义为: 首先令 $h_0 = x$, 即设置第 0 层的特征图为无线电调制数据 x 。之后利用公式(2)卷积计算公式进行卷积操作。

$$h_i = f(W_i \otimes h_{i-1} + b_i) \quad (2)$$

其中 h_i 表示第 i 层的特征图; W_i 第 i 层卷积层的卷积核; b_i 表示第 i 层特征图 h_i 的偏置量; \otimes 表示卷积操作。

经过上述卷积神经网络, 提取到无线电调制数据的空域信息 h_{raw_cnn} , 之后经过两层全连接层进一步提取特征信息得到 CNN 子结构最终的特征提取信息 h_{cnn} 。

(2) 无线电数据时序特征提取—LSTM 子结构

LSTM 是循环神经网络(Recurrent Neural Network, RNN)的变种, 它能够有效避免 RNN 在训练过程中出现的梯度消失问题, 其在长距离依赖问题中的表现更加稳定与优秀, 可以更为精确的捕获数据中的短期或者长期依赖^[37]。LSTM 可以很好得挖掘

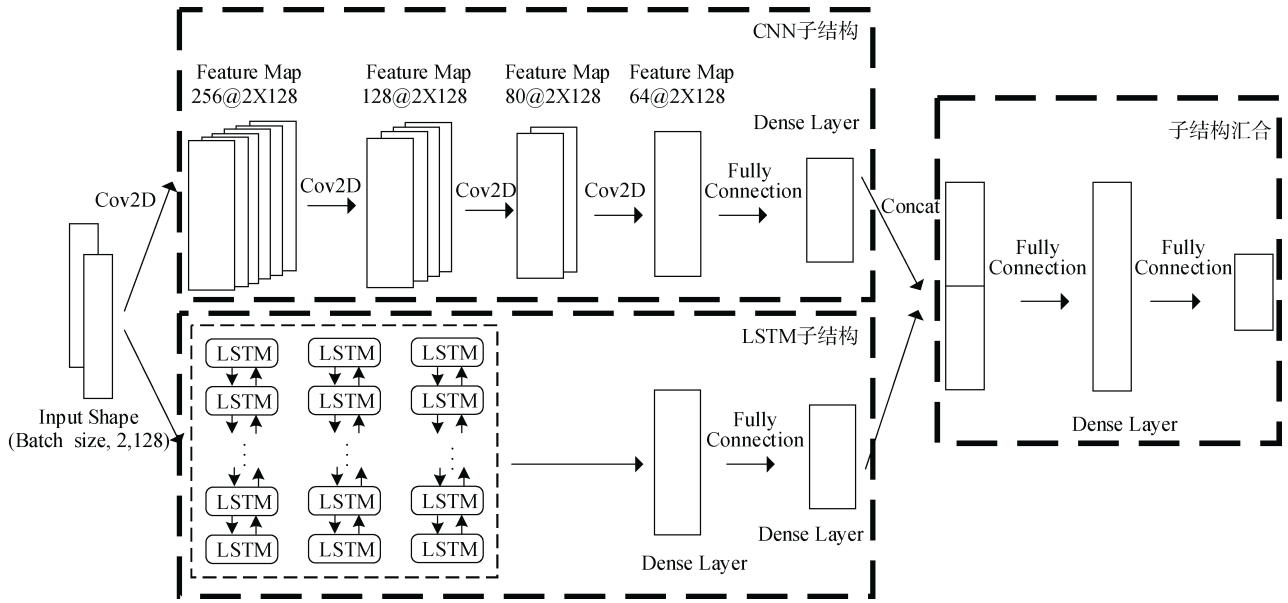


图 4 调制数据分类模型 AMCST 结构图

Figure 4 The architecture of the model AMCST

时序序列中每个节点数据的隐藏时序信息, 因此使用 LSTM 捕获无线电调制数据的时序特征。LSTM 的前向计算方法定义为:

$$i_j = \sigma(W_i[h_{j-1}, x_j] + b_i) \quad (3)$$

$$f_j = \sigma(W_f[h_{j-1}, x_j] + b_f) \quad (4)$$

$$\tilde{C}_j = \tanh(W_c[h_{j-1}, x_j] + b_c) \quad (5)$$

$$o_j = \sigma(W_o[h_{j-1}, x_j] + b_o) \quad (6)$$

$$C_j = \tilde{C}_j \odot i_j + f_j \odot C_{j-1} \quad (7)$$

$$h_j = C_j \odot \tanh(C_j) \quad (8)$$

其中 W_i, W_f, W_c, W_o 为 LSTM 门控单元的权重矩阵, b_i, b_f, b_c, b_o 表示偏置向量, $\tanh(\cdot)$ 表示双曲正切函数, \odot 表示逐项乘积操作。隐藏状态向量 h_{j-1} 表示前一个 LSTM 单元输出的状态信息, 其聚合了无线电调制数据 x 中 $1 \sim (j-1)$ 范围的数据特征。 C_{j-1} 表示前一个 LSTM 单元的记忆门信息。

经过多层 LSTM 结构获取时序网络对无线电调制数据时序信息的提取 h_{raw_lstm} , 之后经过双层全连接网络进一步提取特征信息, 并获取 LSTM 子结构的最终特征信息抽取 h_{lstm} 。

(3) 综合空域特征与时序特征—子结构汇合

对输入的无线电调制数据, 分别经过上述的 CNN 子结构与 LSTM 子结构, 可以得到 h_{cnn} 与 h_{lstm} 。 h_{cnn} 主要保存了卷积神经网络对调制数据空域特征的提取, h_{lstm} 主要保存了长短期记忆网络对调制数

据时序特征的提取。为保证分类模型对时序特征与空域特征的综合度量, 本文此处将 h_{cnn} 与 h_{lstm} 进行聚合, 进行拼接操作:

$$h_{concat} = h_{cnn} \parallel h_{lstm} \quad (9)$$

其中 \parallel 表示拼接操作, h_{concat} 表示两个向量拼接之后结果。

将拼接向量 h_{concat} 经过两层全连接神经网络, 进一步提取无线电调制数据时序特征与空域特征, 最后一个全连接层后增加 SoftMax 层, 用于获取调制分类模型对待估计样本的最终预测结果 h_{final} 。调制分类模型具体优化的目标函数如公式(10)所示:

$$Loss = -\sum_{n=1}^{|C|} y_n \log(\hat{y}_n) \quad (10)$$

其中 $|C|$ 表示调制类别的类别数, y_n 表示调制数据 x 的真实调制类别, \hat{y}_n 表示数据经过上述调制分类模型的预测结果类别。

调制分类模型 AMCST 模型的具体模型结构如图 4 所示。其中 CNN 子结构包含四层卷积层与一层全连接层, 每层卷积层后都增加一个 Dropout 操作。LSTM 子结构包含三层双向 LSTM 结构, 三层 LSTM 结构分别包含 80、64 与 32 个 LSTM 单元。CNN 子结构与 LSTM 子结构均以无线电调制增扩数据为输入。子结构混合模型以 CNN 子结构与 LSTM 子结构的输出拼接之后的结果为输入, 其包含两层全连接层, 神经元数量分别为 256 与 11, 最后对全连接层输出结果做 Softmax 运算, 得到输出模型对输入数据的预测类别标签。模型算法的具体描述如下所示:

算法: 调制数据分类模型 AMCST

输入: 增扩数据集 X , 增扩数据集类别 Y

输出: 分类模型预测分类类别 \hat{Y}

1. for epoch in range(epoches):

2. /*CNN 子结构*/

3. $H_{raw_cnn} \leftarrow \text{CNN 子结构}(X)$ (公式 2、3)

4. /*LSTM 子结构*/

5. $H_{raw_lstm} \leftarrow \text{LSTM 子结构}(X)$ (公式 4~11)

6. /*子结构混合*/

7. $H_{concat} \leftarrow \text{特征拼接}(H_{cnn}, H_{lstm})$ (公式 12)

8. $H_{final} \leftarrow \text{获取最终特征提取}$ (公式 13)

9. $\hat{Y} \leftarrow \max(\text{soft max}(H_{final}))$ 计算增扩数据集预

测标签

10. $loss \leftarrow \text{计算损失}(Y, \hat{Y})$ (公式 14)

11. 更新参数损失($loss$)

12. 最终分类模型对数据集的预测类别 \hat{Y}

5 数据集介绍

数据集 RadioML2016.10a 是一个专门的无线电调制数据集。数据采集的过程中充分考虑了采样率偏移、中心频率偏移、多径衰落和加性高斯白噪声等因素对无线电调制数据的影响。数据集总共包含 22 万条无线电调制数据, 调制数据涉及 20 个不同的信噪比, 信噪比数值范围从 -20dB 到 18dB, 步长为 2dB; 共包含 11 种调制类别, 分别是二进制相移键控(BPSK)、正交相移键控(QPSK)、8 移相键控(8PSK)、连续相位频移键控(CPFSK)、高斯频移键控(GFSK)、4 阶脉冲幅度调制(PAM4)、正交幅度调制(QAM16)、相正交振幅调制(QAM64)、双边带调幅(AM-DSB)、单边带调幅(AM-SSB)和宽带调频(WB-FM)。此外, 每条无线电调制数据由 128 个连续调制的同相位(I)信号和正交相位(Q)信号组成。

5.1 基线模型

(1) 调制数据增扩模型

将基于旋转变换的无线电调制数据增扩模型与本文我们提出的基于生成对抗网络的无线电调制数据增扩模型 RMAbGAN 进行比较, 以验证所提出的数据增强方法的有效性。

基于旋转变换的无线电调制数据增扩模型^[19]: 将无线电调制数据视为“图片”, 对“图片”数据进行一定角度的几何旋转以实现无线电调制数据的增强扩充。本论文设定的旋转角度 θ 为 $\pi/2$ 。

(2) 调制数据分类模型

将基于 CNN 的调制分类模型、基于 LSTM 调制分类模型、基于 ResNet 的调制分类模型、多分类逻辑回归模型以及多分类 K 近邻模型与我们提出的调制分类模型 AMCST 进行比较, 以验证所提出调制分类模型的有效性。

基于 CNN 的调制分类模型^[16]: 该模型由两层卷积层与两层全连接层构成, 其中卷积层卷积核数量分别为 64 与 16, 两层全连接层分别包含 128 个神经元与 11 个神经元。

基于 LSTM 的调制分类模型^[14]: 该模型包含两层长短期记忆网络与两层全连接层, 其中两层长短期记忆网络各包含 128 个 LSTM 单元, 两层全连接层分别包含 128 个神经元与 11 个神经元。

基于 ResNet 的调制分类模型^[38]: 基于残差块 Residual Unit 单元构建 Residual Stack 单元, 调制分类模型由六层 Residual Stack 单元与三层全连接层组成。

多分类逻辑回归模型^[39]: 在仅适用于二分类的逻辑回归模型的基础上进行改进, 如损失函数调整或者类别测算方法修改, 使其适应多分类场景。

多分类 K 近邻模型: KNN 算法确定待测样本类别依据最邻近的样本数据的类别决定。

其中, 关于无线电调制分类模型, 以 8:2 的比例将增扩数据集划分为训练集与测试集, 调制数据增扩模型与调制分类模型 AMCST 的优化器均使用 Adam^[40]。多分类逻辑回归模型与多分类 K 近邻模型使用 scikit-learn 库函数构建, 其中多分类 K 近邻算法的 K 取值为无线电调制类别数。

5.2 模型结果分析

(1) 基于生成对抗网络的无线电调制数据增扩模型 RMAbGAN 结果分析

本文测试了调制分类模型 AMCST、基于 ResNet 的调制分类模型、基于 CNN 的调制分类模型、基于 LSTM 的调制分类模型、多分类逻辑回归模型以及多分类 K 近邻模型 6 个分类模型在原始无线电调制数据集、增扩规模为 10%、20%、50%与 100%情况下调制数据的分类准确率, 其分类准确率具体情况如图 5 所示。

从图 5 中可以出, 信噪比相同的情况下, 随着数据增扩规模的扩大, 调制样本数据分类准确率也不断的提高。这表明本文提出的基于生成对抗网络的数据增扩模型 RMAbGAN 生成的“伪造”数据对提高无线电调制分类准确率是有帮助的。

在同一个数据增扩比例下, 调制样本数据分类

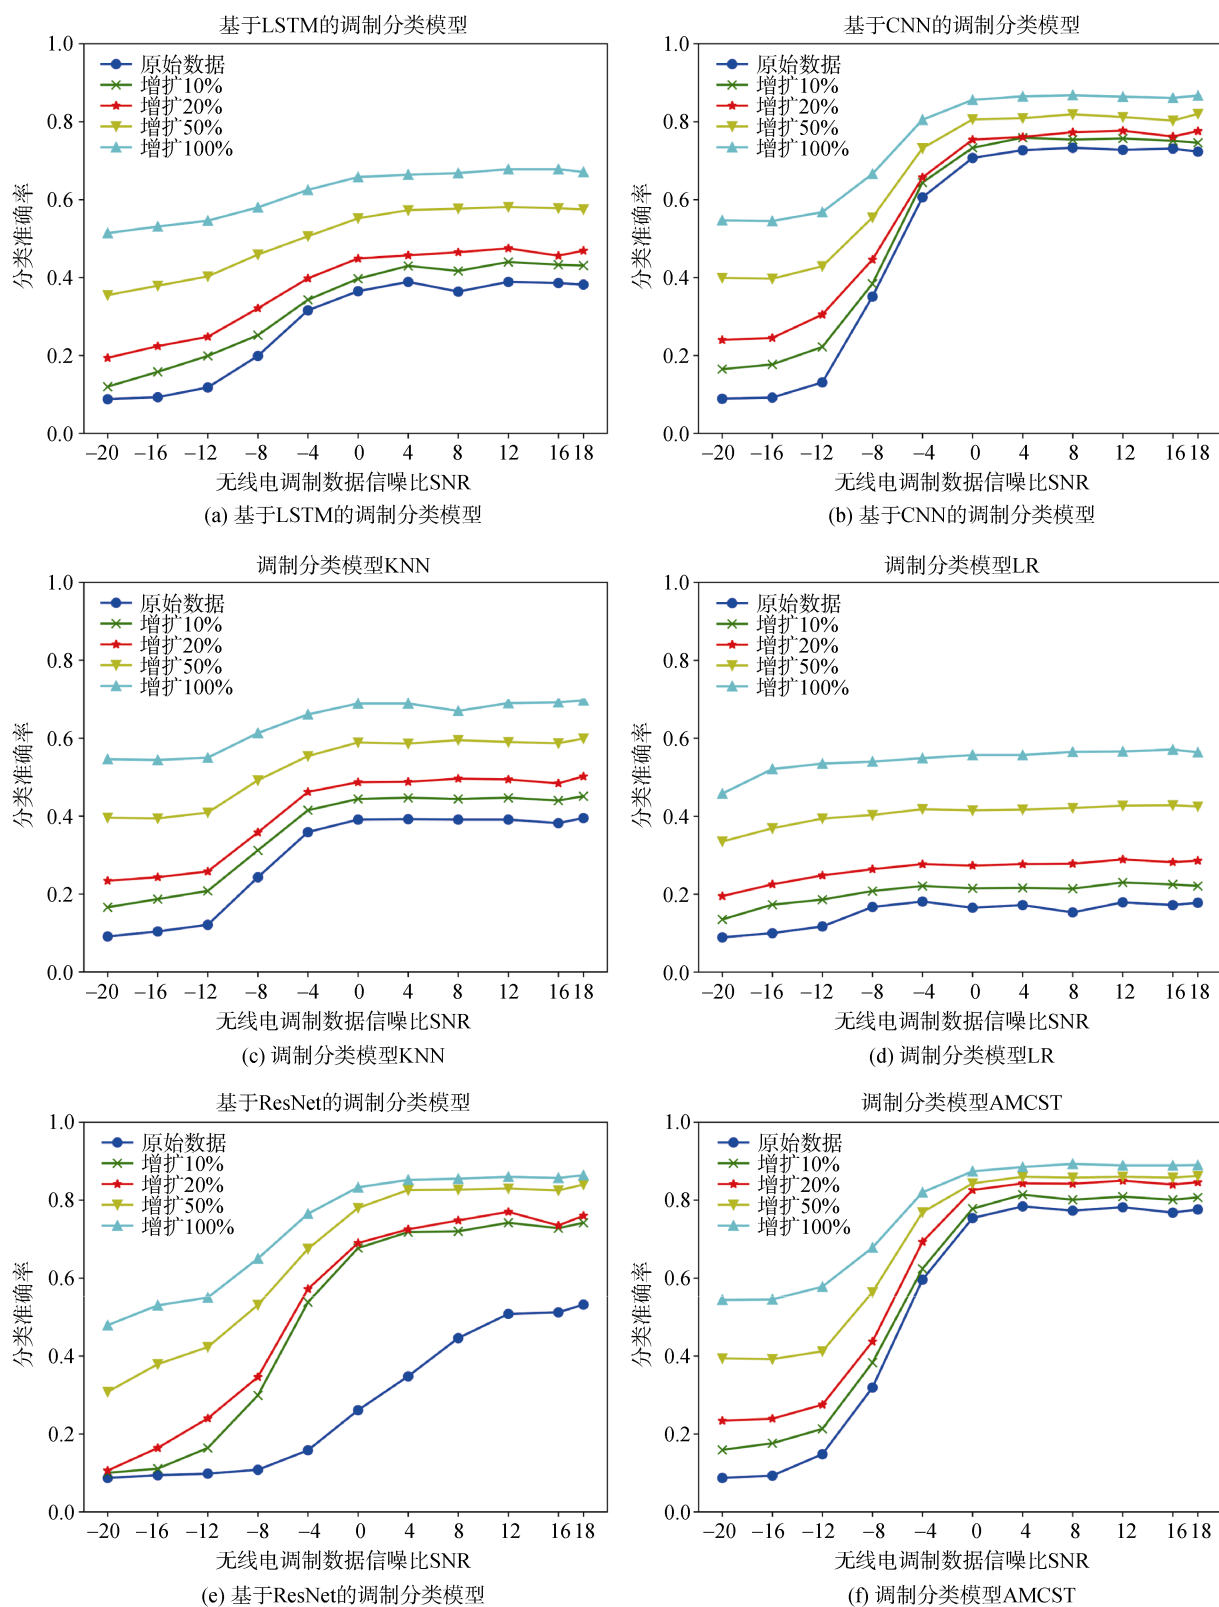


图5 无线电增扩数据分类准确率之调制数据增扩模型 RMAbGAN

Figure 5 Performance of model RMAbGAN

准确率随着信噪比的提高不断增大。这与通信领域关于信噪比对无线电调制数据的影响的认识是一致的。随着增扩数据规模的扩大,低信噪比的调制分类准确率不断提高,低信噪比分类准确率较低的问题

也得到了改善,但是仍旧存在不同信噪比调制分类准确率相差较大的问题,这个问题也是后续相关工作急需解决的。

调制分类模型 AMCST、基于 CNN 的调制分类

模型、基于 LSTM 的调制分类模型与基于 ResNet 的调制分类模型四者相比, 其总体均符合分类准确率随信噪比增加而增大的规律。在信噪比为 -20dB ~ -4dB 且数据增扩规模相同的情况下, 我们提出的调制分类模型 AMCST 与基于 CNN 的调制分类模型数据分类准确率大致相同, 两者分类准确率相较于基于 LSTM 的调制分类模型与基于 ResNet 的调制分类模型有所提升; 相同的数据增扩规模且信噪比为 -4dB ~ 18dB 情况下, 基于 CNN 调制分类模型与基于 ResNet 的调制分类模型分类准确率大致相同, 调制分类模型 AMCST 的数据分类准确率最高, 相较于传统的 CNN 调制分类模型、基于 LSTM 的调制分类模型与基于 ResNet 的调制分类模型分类准确率有不同幅度的提高。这主要是因为我们提出的调制分类模型 AMCST, 相较于另外三个分类模型对于调制信号数据的时序信息与空域信息的做了更为全面的考虑。调制分类模型 AMCST 相较于基于 LSTM 的调制分类模型对无线电数据规模与无线电信号信噪比更为敏感, 整体准确率明显高于后者; 调制分类模型 AMCST 相较于基于 CNN 的调制分类模型对无线电数据增扩规模与无线电信号信噪比敏感度大幅下降, 整体准确率的提升幅度也较低。综合分析来看, 调制分类模型 AMCST 是长短期记忆网络与卷积神经网络的结合体, 是对无线电数据空域特征与时序特征的综合捕获, 结合前述对比结果, 表明无线电调制数据中空域特征更为凸显且更易捕获, 时域特征相对空域特征表现较为平凡, 这与基于 LSTM 的调制分类模型与基于 CNN 的调制分类模型在不同比例下调制准确率结果是相符合的。

图 5 所示随着数据增扩比例的增大, 调制分类模型 AMCST 分类准确率提升幅度不如基于 CNN 的调制分类模型。这主要是由于调制分类模型 AMCST 在较低增扩比例下便实现更高的分类准确率, 对无线电数据特征的挖掘更加完备, 其对数据数量的敏感程度不如基于 CNN 的调制分类模型。

传统的多分类逻辑回归模型与多分类 K 近邻模型相较于调制分类模型 AMCST、基于 CNN 的调制分类模型以及基于 LSTM 的调制分类模型准确率整体偏低, 这主要是由于无线电调制数据本身具有的时序特征与空域特征是非线性的, 从而导致逻辑回归模型效果较差, 相反, 深度神经网络在非线性数据特征提取方面具有优势, 因此整体效果较好; 不同信噪比与调制类别的无线电调制数据分布特征差异较大, 这给多分类 K 近邻模型的调制分类带来了挑战, 导致其并不能达到较好的分类效果。

图 6 中的(a)(b)图分别展示了信噪比为 -8dB 增扩规模为 20% 与 100% 情况下, 调制分类模型 AMCST 识别增扩数据所获得的分类混淆矩阵。显而易见, 数据增扩规模为 100% 的情况下数据分类准确率更高, 可见数据规模对分类模型准确率高度的影响是较大的。其中主要表现为 8PSK、BPSK、CPFSK 与 QPSK 等类别无线电调制数据被误认为 AM-SSB 类别, 这主要是由于信噪比为 -8dB , 上述五种调制类别数据分布特征过于相似, 这在原始数据集的数据分布统计中是可以发现的。

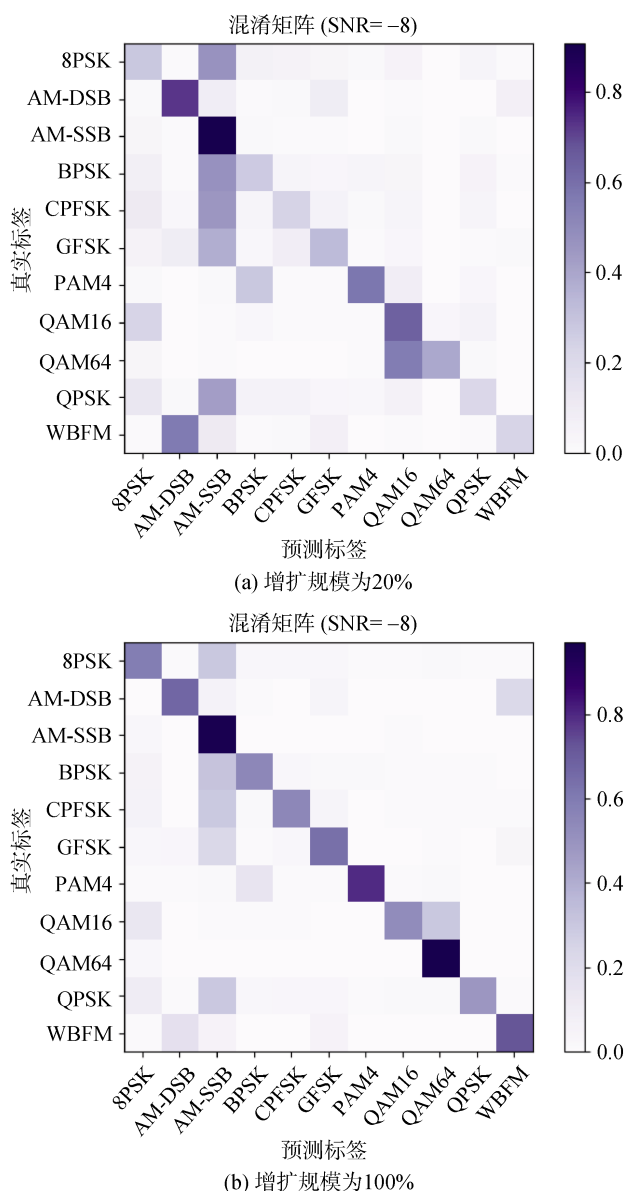



图 6 调制分类模型 AMCST 在信噪比为 -8dB , 增扩规模为 20% 与 100% 的分类混淆矩阵


Figure 6 Comparison of the confusion matrices for (a) $S = 20\%$ (b) $S = 100\%$ with $\text{SNR} = -8\text{dB}$

图 7 中的(a)(b)图分别展示了增扩规模为 100%

的情况下调制分类模型 AMCST 与传统的 CNN 调制分类模型的训练损失图。其中可以看出调制分类模型 AMCST 相较于后者可以更快的实现收敛, 大约 25 个 epoch 后就可以达到较低的训练损失与验证损失。



(a) 调制分类模型AMCST



(b) 基于CNN的调制分类模型


图 7 增扩规模为 100%, 调制分类模型训练损失图
Figure 7 Training performance under different radio data classification model when $S = 100\%$

图 8 中的(a)(b)图分别展示了增扩规模为 100% 信噪比分别为 10DB 与-10DB 情况下, 调制分类模型 AMCST 识别增扩数据所获得的分类混淆矩阵。显而易见, 信噪比为 10DB 的分类准确率要大于信噪比为 -10DB 的分类准确率。这主要是由于信噪比对无线电调制数据的影响。信噪比为-10DB 的混淆矩阵表现出对 QAM16 与 QAM64 之间的主要混淆。


(2) 基于旋转变换的无线电调制数据增扩模型结果分析

图 9 展示了基于旋转变换的无线电调制数据增扩模型所生成的增扩数据在基于 CNN 的调制分类模型、基于 LSTM 的调制分类模型与调制分类模型 AMCST 下的准确率。针对不同的无线电调制数据增

扩规模, 调制分类模型 AMCST 准确率明显高于其他模型, 这主要是由于调制分类模型 AMCST 更充分的捕获了无线电调制数据的时序特征信息与空域特征信息。



(a) 信噪比为10DB



(b) 信噪比为-10DB

图 8 调制分类模型 AMCST 在增扩规模为 100%, 信噪比为 10DB 与-10DB 的分类混淆矩阵
Figure 8 Comparison of the confusion matrices for (a)SNR=10DB(b)SNR= -10DB with $S = 100\%$

随着无线电调制数据增扩规模的增加, 调制分类模型 AMCST、基于 CNN 的调制分类模型以及基于 LSTM 的调制分类模型并没有表现出明显的调制分类准确率的提升。主要与无线电调制数据增强方式有关, 因为数据来源于原始无线电调制数据集的采样, 将采样数据视为“图片”仅对其进行旋转操作, 这并未挖掘更深层次的无线电数据分布特征, 也并未本质上改变此张“图片”, 因此增扩数据与原始调

制数据的分布特征相似, 故导致增扩数据调制识别准确率与原始调制数据分类准确率差异较小。

(3) 模型对比与复杂度分析

对比图 5 图 9 两种无线电调制数据增扩方法, 可以得出基于生成对抗网络的无线电调制数据增扩模型 RMAbGAN 相较于基于旋转变换的无线电调制数据增扩模型准确率较高, 在较低信噪比下更为明

显, 主要是由于调制数据增扩模型 RMAbGAN 针对指定类别的无线电调制数据进行增强, 相较于仅通过旋转变换并未改变数据分布实质的数据增强方法, 使用生成对抗网络可以捕获此类别无线电调制数据的深层次数据特征, 更好的挖掘不同调制类别与信噪比的无线电调制数据分布特征差异, 因此增扩数据识别率也相对较高。

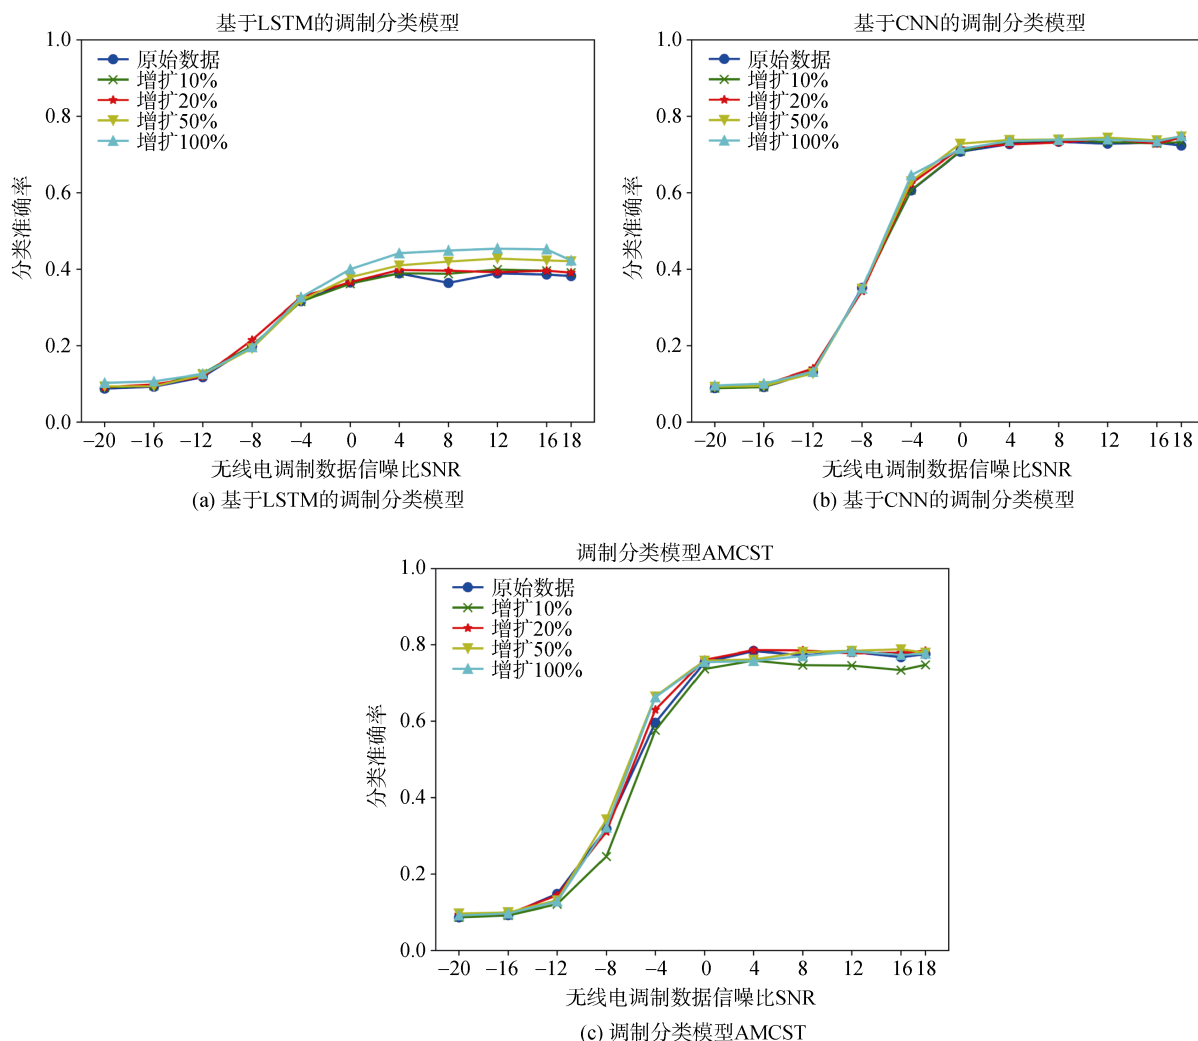


图 9 无线电增扩数据分类准确率之基于旋转变换的无线电调制数据增扩模型

Figure 9 Performance of the radio modulation data augmentation model based on rotation transformation

在复杂度方面, 调制数据增扩模型 RMAbGAN 的复杂度相较于基于旋转变换的无线电调制数据增扩模型较高, 几何旋转操作仅包含矩阵乘法等简单基本运算, 深度生成对抗网络需要对深度神经网络进行正向传播计算与反向梯度下降计算, 需要较多的时间与空间, 但后者生成的增扩数据质量较高。本文涉及六种调制分类模型, 多分类 K 近邻算法利用向量距离度量相似性, 其算法较为简单; 基于 ResNet 的调制分类模型、调制分类模型 AMCST、基于 CNN 的调制分类模型、基于 LSTM 的调制分类模

型同样涉及到神经网络的正向传播计算与反向梯度下降计算, 计算过程复杂; 调制分类模型 AMCST 是时序特征与空域特征的综合捕获, 相较于基于 CNN 的调制分类模型与基于 LSTM 的调制分类模型需要更多的时间与空间, 但调制分类模型 AMCST 的调制识别准确率也较高。

6 结束语

本文提出了一种基于生成对抗网络的无线电调制数据增扩方法。其主要是利用 GAN 捕获样本数据

分布,生成具有原始数据分布特征的高质量“伪造”数据,从而解决获取无线调制数据困难与成本较高的问题;优化了调制数据分类模型,提出了调制分类模型 AMCST,提高了调制数据的分类准确率。通过在公共数据集上的实验,证明了所提出的数据扩增方法可以极大地提高调制分类模型 AMCST 分类准确率。在未来的工作中,我们将研究其他深度学习模型,如变分自编码器及其变种,在调制数据扩增领域的应用。

参考文献

- [1] Liu G P. *Research on development strategy of radio spectrum resource management*[D]. Jinan: Shandong University of Finance and Economics, 2016.
(刘国平. 无线电频谱资源管理发展策略研究——以山东省为例[D]. 济南: 山东财经大学, 2016.)
- [2] Yang C. *Machine learning based research on resource allocation of cognitive radio*[D]. Nanjing: Nanjing University of Posts and Telecommunications, 2021.
(杨岑. 基于机器学习的认知无线网络资源分配研究[D]. 南京: 南京邮电大学, 2021.)
- [3] Yang F Q, Li Z, Luo Z L. Method of Modulation Recognition of Mixed Modulation Signal[J]. *Acta Scientiarum Naturalium Universitatis Sunyatseni*, 2014, 53(1): 42-46.
(杨发权, 李赞, 罗中良. 混合调制信号调制识别方法[J]. *中山大学学报(自然科学版)*, 2014, 53(1): 42-46.)
- [4] Li J C. *Research on modulation identification of digital signals based on deep learning*[D]. Harbin: Harbin Engineering University, 2017.
(李佳宸. 基于深度学习的数字调制信号识别方法研究[D]. 哈尔滨: 哈尔滨工程大学, 2017.)
- [5] Chen X. *Research on automatic modulation classification of digital signals based on deep learning*[D]. Xi'an: Xidian University, 2018.
(陈曦. 基于深度学习的数字信号调制方式识别方法研究[D]. 西安: 西安电子科技大学, 2018.)
- [6] Ma H, Tang R B, Zhang Y, et al. Survey on Speech Recognition[J]. *Computer Systems & Applications*, 2022, 31(1): 1-10.
(马晗, 唐柔冰, 张义, 等. 语音识别研究综述[J]. *计算机系统应用*, 2022, 31(1): 1-10.)
- [7] Guo M Y, Zhang X L, Tang H L, et al. Research on Application of Artificial Intelligence in Machine Translation[J]. *Journal of Henan University of Science and Technology (Natural Science)*, 2021, 42(3): 97-104, 8.
(郭明阳, 张晓玲, 唐会玲, 等. 人工智能在机器翻译中的应用研究[J]. *河南科技大学学报(自然科学版)*, 2021, 42(3): 97-104, 8.)
- [8] LeCun Y, Bengio Y. Convolutional networks for images, speech, and time series[J]. *The handbook of brain theory and neural networks*, 1995, 3361(10): 1-14.
- [9] Chen G Y. *Research on automatic modulation recognition based on deep learning*[D]. Chengdu: Southwest Jiaotong University, 2020.
(陈观业. 基于深度学习的自动调制识别研究[D]. 成都: 西南交通大学, 2020.)
- [10] Zhu X H, Qian L P, Fu W. Overview of Research on Image Data Enhancement Technology[J]. *Software Guide*, 2021, 20(5): 230-236.
(朱晓慧, 钱丽萍, 傅伟. 图像数据增强技术研究综述[J]. *软件导刊*, 2021, 20(5): 230-236.)
- [11] Taylor L, Nitschke G. Improving Deep Learning with Generic Data Augmentation[C]. *2018 IEEE Symposium Series on Computational Intelligence*, 2019: 1542-1547.
- [12] 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.
- [13] Inoue H. Data Augmentation by Pairing Samples for Images Classification[EB/OL]. 2018: arXiv: 1801.02929. <https://arxiv.org/abs/1801.02929>.
- [14] Zhang H Y, Cisse M, Dauphin Y N, et al. Mixup: Beyond Empirical Risk Minimization[EB/OL]. 2017: arXiv: 1710.09412. <https://arxiv.org/abs/1710.09412>.
- [15] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative Adversarial Networks[J]. *Communications of the ACM*, 2020, 63(11): 139-144.
- [16] Cubuk E D, Zoph B, Mane D, et al. AutoAugment: Learning Augmentation Policies from Data[EB/OL]. 2018: arXiv: 1805.09501. <https://arxiv.org/abs/1805.09501>.
- [17] Wei J, Zou K. EDA: Easy Data Augmentation Techniques for Boosting Performance on Text Classification Tasks[EB/OL]. 2019: arXiv: 1901.11196. <https://arxiv.org/abs/1901.11196>.
- [18] Ko T, Peddinti V, Povey D, et al. Audio augmentation for speech recognition[C]. *Sixteenth annual conference of the international speech communication association*. 2015.
- [19] Huang L, Pan W J, Zhang Y, et al. Data Augmentation for Deep Learning-Based Radio Modulation Classification[J]. *IEEE Access*, 2019, 8: 1498-1506.
- [20] Patel M, Wang X Y, Mao S W. Data Augmentation with Conditional GAN for Automatic Modulation Classification[C]. *The 2nd ACM Workshop on Wireless Security and Machine Learning*, 2020: 31-36.
- [21] Platt J C. Sequential Minimal Optimization: A Fast Algorithm for Training Support Vector Machines[J]. *Microsoft Research*, 1998.DOI:US4558132 A.
- [22] Keller J M, Gray M R, Givens J A. A Fuzzy K-Nearest Neighbor Algorithm[J]. *IEEE Transactions on Systems, Man, and Cybernetics*, 1985, SMC-15(4): 580-585.
- [23] Cheng L L, He P L, Sun Y H. Study on Chinese Keyword Extraction Algorithm Based on Naïve Bayes Model[J]. *Computer Applications*, 2005, 25(12): 2780-2782.
(程岚岚, 何丕廉, 孙越恒. 基于朴素贝叶斯模型的中文关键词提取算法研究[J]. *计算机应用*, 2005, 25(12): 2780-2782.)
- [24] O'Shea T J, Corgan J, Clancy T C. Convolutional Radio Modulation Recognition Networks[C]. *International Conference on Engineering Applications of Neural Networks*, 2016: 213-226.
- [25] Huynh-The T, Hua C H, Pham Q V, et al. MCNet: An Efficient CNN Architecture for Robust Automatic Modulation Classification

- tion[J]. *IEEE Communications Letters*, 2020, 24(4): 811-815.
- [26] 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.
- [27] Rajendran S, Meert W, Giustiniano D, et al. Deep Learning Models for Wireless Signal Classification with Distributed Low-Cost Spectrum Sensors[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2018, 4(3): 433-445.
- [28] Ramjee S, Ju S T, Yang D Y, et al. Fast Deep Learning for Automatic Modulation Classification[EB/OL]. 2019: arXiv: 1901.05850. <https://arxiv.org/abs/1901.05850>.
- [29] Chen Y. *Research on modulation signal recognition technology based on deep learning*[D]. Nanchang: Nanchang University, 2021. (陈颖. 基于深度学习的调制信号识别技术研究[D]. 南昌: 南昌大学, 2021.)
- [30] Liu P R. *Research on digital signal modulation recognition based on deep learning*[D]. Xi'an: Xi'an University of Science and Technology, 2021. (刘佩茹. 基于深度学习的数字信号调制识别方法研究[D]. 西安: 西安科技大学, 2021.)
- [31] Tian D Y. *Research on modulation type recognition of communication signal based on deep learning*[D]. Xi'an: Xidian University, 2019. (田得雨. 基于深度学习的通信信号调制类型识别研究[D]. 西安: 西安电子科技大学, 2019.)
- [32] Fan C X. *Lectures on communication principles*[M]. Beijing: Publishing House of Electronics Industry, 2005: 178. (樊昌信. 通信原理教程[M]. 北京: 电子工业出版社, 2005: 178.)
- [33] Zhang H. *Research on communication signals modulation recognition method based on machine learning*[D]. Harbin: Harbin Engineering University, 2020. (张慧. 基于机器学习的通信信号调制识别方法研究[D]. 哈尔滨: 哈尔滨工程大学, 2020.)
- [34] Wang Z L, Zhang B W. Survey of Generative Adversarial Network[J]. *Chinese Journal of Network and Information Security*, 2021, 7(4): 68-85. (王正龙, 张保稳. 生成对抗网络研究综述[J]. *网络与信息安全学报*, 2021, 7(4): 68-85.)
- [35] He L, Li Y X, Peng B, et al. Road Extraction with UAV Images Based on Generative Adversarial Networks[J]. *Journal of University of Electronic Science and Technology of China*, 2019, 48(4): 580-585. (何磊, 李玉霞, 彭博, 等. 基于生成对抗网络的无人机图像道路提取[J]. *电子科技大学学报*, 2019, 48(4): 580-585.)
- [36] Zhou F Y, Jin L P, Dong J. Review of Convolutional Neural Network[J]. *Chinese Journal of Computers*, 2017, 40(6): 1229-1251. (周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. *计算机学报*, 2017, 40(6): 1229-1251.)
- [37] Yang L, Wu Y X, Wang J L, et al. Research on Recurrent Neural Network[J]. *Journal of Computer Applications*, 2018, 38(S2): 1-6, 26. (杨丽, 吴雨茜, 王俊丽, 等. 循环神经网络研究综述[J]. *计算机应用*, 2018, 38(S2): 1-6, 26.)
- [38] 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.
- [39] Shen Y W. *Micro-expression recognition model based on multi-class logistic regression*[D]. Xuzhou: China University of Mining and Technology, 2020. (申俞文. 基于多分类逻辑回归的微表情识别模型[D]. 徐州: 中国矿业大学, 2020.)
- [40] Kingma D P, Ba J. Adam: A Method for Stochastic Optimization[EB/OL]. 2014: arXiv: 1412.6980. <https://arxiv.org/abs/1412.6980>.



张凤荔 于 2007 年在电子科技大学计算机应用技术专业获得工学博士学位。现任电子科技大学信息与软件工程学院教授。研究领域为软件理论、网络安全与网络工程、云计算与大数据、智能计算。Email: fzhang@uestc.edu.cn



周志远 于 2020 年在成都信息工程大学软件工程专业获得学士学位。现在电子科技大学软件工程专业攻读硕士学位。研究领域为智能计算、数据挖掘与网络嵌入。Email: 18382418120@163.com



王瑞锦 于 2013 年在电子科技大学信息与通信工程专业获得博士学位。现任电子科技大学信息与软件工程学院副教授。研究领域为网络与信息安全、区块链、知识图谱、人工智能。Email: ruijinwang@uestc.edu.cn