Radar Science and Technology

DOI:10.3969/j.issn.1672-2337.2024.01.014

基于数据增强的小样本辐射源个体识别方法

王艺卉^{1,2},闫文君¹,段可欣^{1,3},于楷泽^{1,3}

(1. 海军航空大学,山东烟台 264001; 2. 31401部队,山东烟台 264001; 3. 91423部队,山东烟台 264001)

摘 要:针对样本数据难获取、捕捉样本类别不全面等样本不足的小样本学习识别准确率不高的困境,提 出基于数据增强的小样本辐射源个体识别方法。首先,通过时域翻转、振幅反转、振幅缩放和噪声处理等方法对 小样本数据集进行数据集扩充;其次,将噪声序列和类别标签输入生成器进一步生成"以假乱真"的生成样本,提 高生成样本的多样性并通过辅助分类器同步完成真假样本判别和类别预测;最后,根据判别器动态反馈渐进式 调整损失函数权值,重点关注高质量样本进一步优化网络,提高识别准确性。

关键词:辐射源个体识别;小样本;数据增强;辅助分类生成对抗网络

中图分类号:TN911.7 文献标志码:A 文章编号:1672-2337(2024)01-0104-07

引用格式:王艺卉,闫文君,段可欣,等.基于数据增强的小样本辐射源个体识别方法[J]. 雷达科学与技术, 2024,22(1):104-110.

WANG Yihui, YAN Wenjun, DUAN Kexin, et al. Few-Shot Sample Specific Emitter Identification Method Based on Data Augmentation[J]. Radar Science and Technology, 2024, 22(1):104-110.

Few-Shot Sample Specific Emitter Identification Method Based on Data Augmentation

WANG Yihui^{1,2}, YAN Wenjun¹, DUAN Kexin^{1,3}, YU Kaize^{1,3}

(1. Naval Aviation University, Yantai 264001, China; 2. Unit 31401 of PLA, Yantai 264001, China; 3. Unit 91423 of PLA, Yantai 264001, China)

Abstract: Aiming at the dilemma of low recognition accuracy of few-shot learning and due to difficult acquisition of sample data and incomplete capture sample categories, a method for few-shot specific emitter identification (SEI) based on data enhancement is proposed. Firstly, the dataset is expanded by time domain flipping, amplitude inversion, amplitude scaling and noise processing. Secondly, the noise sequence and the category label are input into the generator to further generate the "false and true" generated samples, which improves the diversity of the generated samples and synchronously completes discrimination and category prediction of true and false samples through the auxiliary classifier. Finally, according to the dynamic feedback of the discriminator, the weight of the loss function is gradually adjusted, and the network is further optimized by focusing on high-quality samples to improve the recognition accuracy.

Key words: specific emitter identification (SEI); few-shot samples; data augmentation; auxiliary classifier GAN

0 引 言

辐射源个体识别(Specific Emitter Identification, SEI)在通信对抗、频谱资源监测与管理、无线 电干扰检测与定位、无线电设备管理与维护等领 域应用广泛^[1],通过准确识别辐射源个体可以锁定 恶意信号或入侵个体^[2],提高频谱利用率与无线电 设备管理的有效性,确保通信系统的干扰冲突最 小化。

在现实通信场景中,常常由于信号遮挡、长距 离传输、电磁干扰、不良天气影响、信号加密等原 因出现样本数据难以获取、捕捉样本类别不全面等样本数目不足的小样本困境。

近年来,小样本问题愈受关注,其问题的解决 掣肘于数据量的缺乏。数据增强技术在图像分 类、目标检测、自然语言处理等领域应用广泛且表 现突出,为小样本困境的解决提供了可能。目前, 较为主流的小样本学习方法有基于度量学习、基 于模型改进和基于数据增强三种方法^[3]。

基于度量学习的方法是通过距离度量样本间 的相似性,具有代表性的有构造正样本、负样本和 锚点来计算样本对间距离的共享网络参数孪生网

基金项目:国家自然科学基金面上项目(No.62271499,62371465);电磁空间安全全国重点实验室开放基金

收稿日期: 2023-08-16; 修回日期: 2023-09-13

络、利用双向长短时记忆的元学习匹配网络、以类 别均值为中心的原型网络,其受限于缺乏数据而 易受离群样本和错误标注样本的影响。基于模型 改进的代表性方法有借助附加的记忆模块保存支 持集中提取的特征信息进行学习的记忆增强的神 经网络算法^[4]、跨任务训练寻优的参数优化方 法^[5]、引入掩码变换网络使得任务参数具体对应子 空间的高维网络参数元学习算法^[6]、引入注意力机 制和互信信息的权重生成小样本算法^[7],显然地, 使用附加记忆模块会提高计算成本和内存间的需 求,优化模型或参数的方法使得难以平衡识别精度 与学习速度。三者之中,数据增强策略更为直接。

数据增强(data augmentation)是一种通过扩充 样本数量而直接有效解决样本不足问题的方法。 在图像处理时常采用翻转^[8•9]、旋转^[10]、移位^[11]、缩 放^[12-13]、噪声扰动^[14]等实现数据扩充的方法可以借 鉴延用到无线电信号领域^[15],这些微小的改动虽 然没有直接增加特征信息,但使得扩充数据集在 特征空间的覆盖范围变大,细微差别的存在使神 经网络将其视为不同的样本,是更加有助于分类 面的选择和鲁棒性的提高。 基于此,本文提出基于数据增强的小样本辐 射源个体识别算法。首先,通过时域翻转、振幅反 转、振幅缩放和噪声处理等方法对小样本数据集 进行数据集扩充;其次,将噪声序列和类别标签输 入生成器进一步生成"以假乱真"的生成样本,提 高生成样本的多样性并通过辅助分类器同步完成 真假样本判别和类别预测;最后,根据判别器动态 反馈渐进式调整损失函数权值,重点关注高质量 样本进一步优化网络,提高识别准确性。

1 数据预处理

1.1 数据特点

本文采用ADS-B 1090 MHz S模式扩展电文数 据链进行分析,其最大下行数据长度达112位,数 据率可达1 Mbit/s。如图1所示,ADS-B消息主要 由前导脉冲(preamble)部分和数据(data block)部 分组成,消息的前导脉冲位置在消息的前端即信 号的前8μs时间,是信息头部分,总共有4个脉 冲。数据部分共112位,表征下行链路格式、通信 能力、飞机唯一标识符、地表位置、空中位置和速 度等信息。



图1	ADS-B	1090ES	信息	数据:	块格:	式及	数据	位P	PM	调制	剖
----	-------	--------	----	-----	-----	----	----	----	----	----	---

ADS-B信号采用脉冲位置调制(PPM)实现数 据位报文编码后在数据链路中传播,其基带 PPM 信号为

$$D(t) = \sum_{v=0}^{239} b_m p(t - mT_s)$$
(1)

式中, b_m 表示第m个二进制符号,p(t)表示一个脉 冲宽度为 $T_s = 0.5 \mu s$ 的矩形脉冲。

1.2 数据增强

聚焦样本不足的核心问题,借鉴图片分类算 法中常用的翻转、平移、拼接等方法对电磁信号进 行时域翻转、振幅反转、振幅缩放和噪声扰动实现 数据扩充。 1.2.1 时域翻转

由图2可知,时域翻转是将信号的时间轴进行翻转,对于ADS-B信号这一离散信号*S*(*n*)而言,时域翻转可表示为

$$S_{\rm r}(n) = S(N - 1 - n)$$
 (2)

式中:N为信号长度;n为时间索引,取值范围为 [0,N-1]。

1.2.2 振幅反转

由图3可知,振幅反转是将信号沿时间轴进行 反转,对于ADS-B信号这一离散信号*S*(*n*)而言,振 幅反转可表示为

$$S_{f}(n) = -S(n) \tag{3}$$

式中,n为时间索引, $S_{f}(n)$ 为振幅反转后的信号。



1.2.3 振幅缩放

由图4可知,振幅缩放是通过缩放因子调整信号的幅度特征,对于 ADS-B 信号这一离散信号 *S*(*n*)而言,振幅缩放可表示为

$$S_{*}(n) = \alpha S(n) \tag{4}$$

式中,n为时间索引, $S_s(n)$ 为振幅缩放后的信号, α 为缩放因子。当将超参数 α 设置为大于1时振幅 增大,小于1时振幅缩小,但过小或过大的缩放因 子会造成信号截断等信号溢出或失真的影响,在 后续实验中选取 $\alpha = 1.4$ 。



1.2.4 加噪处理

对 ADS-B 信号这一离散信号 S(n) 加入高斯噪 声可以表示为

$$S_n(n) = S(n) + N(0, \sigma^2)$$
 (5)

式中:n为时间索引, $S_n(n)$ 为添加高斯噪声后的信号,N是服从均值为0、方差为 σ^2 的高斯分布的随机数,如图5所示。



2 基于数据增强的辐射源个体识别 方法

2.1 辅助分类生成对抗网络

Augustus 等在文献[16]中以GAN 为基础提出 了可同时实现样本分类预测和真假样本判别的辅助分类生成对抗网络(Auxiliary Classifier GAN, AC-GAN),其损失函数分为判别是否为真实样本的损 失*L*_s和分类准确性的损失*L*_c两部分:

$$L_{\rm S} = E_{x \sim P_{\rm data}(x)} \Big[\log (D_{\rm S}(x)) \Big] + E_{z \sim P_z(z)} \Big[\log (1 - D_{\rm S}(G(z, y))) \Big]$$

$$(6)$$

$$L_{\rm C} = -E_{x \sim P_{\rm data}(x)} \Big[L_{\rm D}(y_x | x) \Big] - E_{z \sim P_z(z)} \Big[L_{\rm D}(y | G(z, y)) \Big]$$

$$(7)$$

式中:x真实样本对应类别标签为 y_x ,z和y为输入 生成器的噪声序列和标签,生成样本为G(z,y); $x \sim P_{data}(x)$ 表示样本x服从真实样本分布,将样本x判别为真实样本的概率为 $D_s(x)$,将输入的G(z,y)判别为真实样本的概率为 $D_s(G(z,y))$, L_b 表示为分 类损失,故而AC-GAN判别器损失为

$$\max V(D,G) = L_{\rm s} + L_{\rm c} \tag{8}$$

生成器损失为

 $\max V(D,G) = L_{\rm c} - L_{\rm s} \tag{9}$

2.2 渐进式权值调整的AC-GAN

AC-GAN 在创造性地实现样本真假判别和分 类双重任务的同时,可通过辅助分类器有效控制 生成样本的类别,联合生成器损失、判别器损失和 分类器损失加强模型训练稳定性,但在实际应用 中仍存在以下不足:

1) AC-GAN 在训练数据较少时易引发生成样本多样性不足的问题。

2) AC-GAN 平等地关注判别结果参差不同的 样本,限制了模型的识别能力。

基于此,本文提出渐进式动态调整损失函数 权重的辅助分类生成对抗网络(PW-ACGAN)的辐 射源个体识别算法,合理利用1.2节中对原始样本 进行时域翻转、振幅反转、振幅缩放及噪声扰动等 方法产生的扩充样本提高原数据集的特征覆盖情 况,使得模型能更好地获得数据的分布,提高生成 样本的多样性;根据反馈动态调整损失函数的权 重,更加关注将输入的生成样本*G*(*z*,*y*)判别为真实 样本和将输入真实样本*x*判别为假的"颠倒是非" 的理想欺骗状态,有效降低低质量生成样本对模 型的影响^[17-18],具体步骤如下:

 定义权值调整因子与权重初始化:定义介 于0到1之间的权值调整因子γ以控制生成器的损 失函数权重,表示生成器损失函数的相对权重。
 起初,将生成器和鉴别器损失函数的权重设置为 相等的值,实现初始权重平衡。

2)关注判别结果动态调整γ:在训练过程中 记录生成样本被判别为真实样本(D_s(G(z,y))→1) 和真实样本被判别为生成样本(D_s(x)→0)的判 别概率,在理想情况下,每次判别器输出的概率值 为1/2,即判别器无法区分真实数据和生成数据。

故以 1/2为界,当 $P_{D_s(G(z,y))\to 1}$ 大于 1/2或 $P_{D_s(x)\to 0}$ 的判别概率小于 1/2时,将判别概率与权值调整因子 γ 比较大小,若判别概率P大于 γ 则将 P赋值给 γ ,调整并更新损失函数。

PW-ACGAN 判别器损失为

$$L_{S'} = E_{x \sim P_{dus}(x)} \Big[(1 - \gamma) \log (D_{S}(x)) \Big] + E_{z \sim P_{z}(z)} \Big[\gamma \log (1 - D_{S}(G(z, y))) \Big]$$
(10)

PW-ACGAN生成器损失函数保持不变,判别器损失函数为

$$\max_{D} V(D,G) = L_{S'} + L_C$$
(11)

3) 权值平衡与稳定:过度重视生成样本的逼 真程度会降低生成样本的多样性,过强的生成器 会造成模型崩溃,过强的判别器会引起梯度消失。 通过以1/2为界,γ = max(γ,P)将权值调整因子限 制在0.5至1之间,保持生成样本多样性与逼真性 的平衡。

2.3 实现步骤

如图6所示,信号样本经过数据增强处理后形 成扩充数据集,按设置比例划分成训练集和测试 集,随机抽取m个训练样本x;在PW-ACGAN中,随 机生成m个满足正态分布的噪声序列z和生成样 本标签y经过生成器G输出生成样本G(z,y)。将样 本x和G(z,y)一同送入判别器D判别,并通过反向 传播调整优化生成器与判别器。



3 仿真实验

3.1 仿真条件

3.1.1 数据采集及数据集设置

为采集 ADS-B 信号架设工作频率设置为 20 MHz,采样频率 2 MHz,接收增益为 80 的 USRP-B210 作为信号接收装置采集 1 090 MHz ADS-B S 模式响应信号,信号采集过程如图 7 所示。在航班 密集程度不同的时间段和地点采集 ADS-B 射频信 号并进行抗混叠滤波和步进增益,将信号解调至 中频,经转换与解码处理后得到 ADS-B 报文,其中 部分 ADS-B 信号如图 8 所示。



图7 数据采集场景





为分析类别数目与样本数目对识别结果的影响,现设置多个数据集,其中训练集与测试集比为 3:1。DATA设置类别数量为8,单类别样本数为 32,时域翻转和振幅反转根据真实样本最多只能 1:1生成,故而依1.2节中数据增强方法扩充数据 集时,人为将扩充样本比例设定为1倍。

3.1.2 实验设置

实验基于 TensorFlow的 keras 框架网络模型的设计与训练过程采用 Pycharm 软件完成,硬件配置为 Intel(R) Core(TM) i9-9900K CPU,运行内存 16 GB,主频 3.6 GHz。输入判别器数据尺寸统一为 1×1 000 格式,模型训练过程采用 Adam 优化器进行权值优化,每次迭代样本数为 32,训练次数设置为 30,学习率为 0.01。

3.1.3 网络模型搭建

深度卷积生成对抗网络(Deep Convolution GAN, DCGAN)的提出创造性地将卷积神经网络引入了生成对抗网络^[19],优化了模型的生成质量和稳定性。PW-ACGAN以DCGAN网络结构为基础, 生成器和判别器网络模型设计如表1和表2所示。

表1 PW-ACGAN生成器网络模型

层名称	参数设置
输入层	1×100噪声序列+1×8类别标签
全连接层	128×62
尺度变换	128×62,BN
转置卷积层	Filters=128, Relu, BN
转置卷积层	Filters=64, Relu, BN
转置卷积层	Filters=32, Relu
转置卷积层	Filters=1, Sigmoid
全连接层	1 000
输出层	1×1 000

表2 PW-ACGAN 判别器网络模型

层名称	参数设置
输入层	1×1 000信号序列
卷积层	Filters=18, Relu, BN
卷积层	Filters=14, Relu, BN
卷积层	Filters=8, Relu, BN
尺度变换	360
输出层	判别概率 类别预测

3.2 实验结果分析

3.2.1 不同数据增强方法对识别效果的影响

为验证不同增强方法对识别效果的影响,选 用与PW-ACGAN的判别器结构相同但去除输出层 判别概率分支的CNN网络模型为识别网络。不同 的增强方法在训练样本时取8种类型的信号样本 各32个,分别将未经增强的原始样本记为None、 Time domain flipping、Amplitude reversal、Gaussian noise与组合使用增强方法的混合增强样本Mix在 不同信噪比条件下进行识别效果比较。

由图9可知,不同增强方法的识别准确率在不同信噪比条件下均有不同程度的提高,在信噪比较低的情况下,识别准确率稳步提升,在达到8dB时识别准确率趋于稳定;单一增强方法中时域翻转的增强方法表现最佳,加噪处理的增强方法表现最为逊色,振幅缩放增强方法的识别准确率稍微优于振幅反转;而混合增强方法优于单一增强方法,为优化实验效果后续实验采用混合增强方法产生增强样本。



3.2.2 小样本条件下识别效果分析

为对比 CNN、ACGAN 及 PW-ACGAN 在小样本 条件下的识别效果,在 SNR=2 dB条件下对混合增 强样本 Mix 进行 20次蒙特卡罗实验并记录识别准 确率,绘制盒子图可知其最大最小值、上下四分位 数和中位数及分布情况。

由图 10可知,以图中红色横线标注的中位线 为标准,PW-ACGAN 的识别准确率明显优于 CNN 和 ACGAN 算法;PW-ACGAN 的识别准确率分布最 为集中,表明其平衡了生成样本的稳定性与多样 性,更好地突破了训练集数目少易引发的测试集 易过拟合的小样本限制,进一步证明了 PW-AC-GAN 算法的有效性。

3.2.3 不同识别方法比较

为进一步说明本文算法在小样本辐射源个体 识别中的优势,采用通过对比实验进行分析。其



中,Augmented data with screening 是以文献[20]中 基于粗细粒度筛选的生成对抗网络数据增强方 法;Meta Learning 是以文献[21]中基于元学习的跨 任务信号识别方法;LDCGAN+SVM 是以文献[22] 中基于深度卷积生成对抗网络扩充样本后利用支 持向量机进行分类识别方法。

由图 11 可知,本文所提识别算法在不同的 信噪比条件下均优于其他三种对比算法,尤其 在-10~-2 dB低信噪比条件下,不同识别算法的识 别效果差异显著,本文所提基于混合数据增强和 PW-ACGAN较将LDCGAN生成数据映射到高维特 征空间利用支持向量机分类识别的方法提高了 15% 左右,表明本文算法对低信噪比环境有较好 的适应性。



3.2.4 样本数量对识别效果的影响

小样本学习旨在解决样本不充足、不全面的 条件限制问题,但训练样本数量仍在一定程度上 影响识别结果。首先在信噪比为8的条件下,设置 不同的每个类别样本数量进行识别准确率比较, 查看数据增强在不同数量的小样本条件下的作用 效果。由图 12 横向对比可知,随着每个类别样本数目的增加,识别准确率明显提升,表明充足的训练样本对模型的拟合能力至关重要;纵向来看,在样本数目较少的情况下,数据增强通过扩充样本数量提高样本的特征覆盖率,更好地使模型学习数据特征,从而实现了小样本条件下识别准确率的跃升,但当样本数量较为充足并能够支撑分类器获得较好的分类面时,数据增强的作用效果微弱。



为进一步验证小样本条件下增强样本数量对 识别准确率的影响,取不同数量的增强样本进行 多次实验,取平均识别准确率进行比较。由表3可 知,随着增强样本数量的增加,识别准确率稳步提 升,当达到增强样本数量与原始样本一致时,识别 准确率提升近23%。

表3	各类增强样本在不同数量下的识别准确率

增强样本数量	识别准确率/%
0	69
8	73
16	85
24	87
32	92

4 结束语

针对复杂电磁环境中缺少高质量、数量充足 训练样本的困境,提出基于数据增强的小样本辐 射源个体识别方法。首先,通过数据增强扩充样 本集,提高原数据集的特征覆盖情况,使得模型能 更好地获得数据的分布;然后,将噪声序列和类别 标签输入生成器进一步生成"以假乱真"的生成样 本,提高生成样本的多样性并通过辅助分类器同 步完成真假样本判别和类别预测;最后,根据判别 器动态反馈渐进式调整损失函数权值,重点关注 高质量样本进一步优化网络,提高识别准确性。 实验结果表明,本文算法在不同数量样本下和不 同信噪比条件下均表现出较为稳定的识别能力, 尤其对低信噪比条件具有较好的适应性,为复杂信 道条件下的小样本辐射源个体识别提供了可能。

参考文献:

- [1] 张立民,谭凯文,闫文君,等.基于持续学习和联合特征 提取的特定辐射源识别[J].电子与信息学报,2023,45 (1):308-316.
- [2]方棉佳,陈朝.针对敌我识别系统的个体识别研究[J]. 雷达科学与技术,2023,21(3):298-302.
- [3] 李芳琳. 面向小样本数据的分类与检测方法及应用研 究[D]. 南京:南京邮电大学, 2023.
- [4] SANTORO A, BARTUNOV S, BOTVINICK M, et al. Meta-Learning with Memory-Augmented Neural Networks [C]// International Conference on Machine Learning, New York City, NY, USA: JMLR Workshop and Conference Proceedings, 2016:1842-1850.
- [5] FINN C, ABBEEL P, LEVINE S. Model-Agnostic Meta-Learning for Fast Adaptation of Deep Networks[C]// International Conference on Machine Learning, Los Angeles, CA, USA: JMLR Workshop and Conference Proceedings, 2017:1126-1135.
- [6] RUSU A A, RAO D, SYGNOWSKI J, et al. Meta-Learning with Latent Embedding Optimization [EB/OL]. Arxiv, 2018. https://doi.org/10.48550/arXiv.1807.05960.
- [7] GUO Yiluan, CHEUNG N M. Attentive Weights Generation for Few Shot Learning via Information Maximization [C]// IEEE/CVF Conference on Computer Vision and Pattern Recognition, Seattle, WA, USA: IEEE, 2020:13496-13505.
- [8] ZHU Linchao, YANG Yi. Compound Memory Networks for Few-Shot Video Classification [C]// Computer Vision-ECCV 2018, Munich: Springer Science, 2018:782-797.
- [9] WU Yu, LIN Yutian, DONG Xuanyi, et al. Exploit the Unknown Gradually: One-Shot Video-Based Person Re-identification by Stepwise Learning [C]// IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, UT, USA: IEEE, 2018: 5177-5186.
- [10] ZHAO Fang, ZHAO Jian, YAN Suicheng, et al. Dynamic Conditional Networks for Few-Shot Learning[C]// Computer Vision - ECCV 2018, Munich: Springer (下转第118页)