

文章编号:1006-2467(2022)12-1666-09

DOI: 10.16183/j.cnki.jsjtu.2022.041

基于迁移学习的小样本 OFDM 目标增强识别方法

唐泽宇¹, 邹小虎¹, 李鹏飞¹, 张伟^{1,2}, 余佳奇³, 赵耀东¹

(1. 电子信息控制重点实验室, 成都 610036; 2. 电子科技大学 信息与通信工程学院,
成都 611731; 3. 北京理工大学 计算机学院, 北京 100091)

摘要: 在非合作场景所导致的小样本条件下, 稳健提取通信辐射源目标特征并准确识别目标是当前研究的难点和热点。针对正交频分复用通信辐射源的小样本个体识别问题, 文章在相位域、时域翻转的数据增强和源领域实例迁移的基础上, 提出一种非合作通信辐射源个体识别方法。采用不同域翻转的数据增强方法扩充数据集, 结合改进的残差网络, 达到提高正交频分复用通信辐射源个体识别准确率的目的, 并引入迁移学习以增强识别模型的泛化能力。实验结果表明: 数据增强策略提升了小样本下的正交频分复用通信辐射源个体识别准确率, 迁移学习方法的引入加快了模型的收敛速度, 小幅度提高模型识别准确率并提升了鲁棒性。

关键词: 正交频分复用; 小样本识别; 数据增强; 迁移学习; 深度学习; 目标识别

中图分类号: TN 929.5; TP 18 **文献标志码:** A

A Few-Shots OFDM Target Augmented Identification Method Based on Transfer Learning

TANG Zeyu¹, ZOU Xiaohu¹, LI Pengfei¹, ZHANG Wei^{1,2}, YU Jiaqi³, ZHAO Yaodong¹

(1. Science and Technology on Electronic Information Control Laboratory, Chengdu 610036, China;
2. School of Information and Communication Engineering, University of Electronic Science and
Technology of China, Chengdu 611731, China; 3. School of Computer Science and
Technology, Beijing Institute of Technology, Beijing 100091, China)

Abstract: Under the few-shots condition caused by non-cooperative scenes, robust extraction of communication emitter features and accurate identification of targets are the difficulties and hotspots of current research. Aimed at the problem of emitter identification under the few-shots condition of orthogonal frequency division multiplexing (OFDM) signals, this paper proposes a non-cooperative target identification method based on phase/time domain flipping data augmentation and source domain instance-based transfer learning. The data set is expanded by different domain flipping data augmentation methods, and the improved residual network is applied to achieve the purpose of promoting the identification rate of the OFDM emitter. Then, transfer learning is introduced to strengthen the generalization ability of the identification model. The experimental results show that the data augmentation method can significantly improve the OFDM emitter identification rate under the few-shots condition. Furthermore, the transfer learning method accelerates the convergence speed, slightly increases the recognition rate, and improves robustness of the model.

收稿日期:2022-02-25

基金项目:国家自然科学基金(U20B2070)资助项目

作者简介:唐泽宇(1988-),男,重庆市人,硕士生,从事辐射源识别技术研究。

通信作者:张伟,男,高级工程师,电话(Tel.):028-87550717;E-mail:zhanggwei1103@163.com.

Key words: orthogonal frequency division multiplexing (OFDM); few-shots identification; data augmentation; transfer learning; deep learning; target identification

通信辐射源受制造、工艺、加工等影响,同一批次出厂的同型号设备的元器件也会存在个体差异,从而导致其发射信号中携带与硬件相关的细微特征,且这些特征不受信号具体传输的内容影响。基于此,采用通信辐射源个体识别技术,通过对电磁信号所携带的辐射源硬件特征进行分析,判断电磁信号来源,以确定其用途、型号、威胁等信息,这是有针对性地跟踪、监视和干扰重要目标最基础、最关键的环节,在公共安全管理和国防军事应用中具有重要意义^[1]。同时,由于正交频分复用(OFDM)技术被广泛应用于 4G/5G 移动通信网络、无线局域网、数字音频/视频广播、军民用无线通信链路、军民用无人机控制信号链路等领域,所以对 OFDM 通信辐射源的个体识别研究具有广泛的应用意义。

通信辐射源个体识别本质上是一个机器学习分类与识别问题,通过对已知通信辐射源类别信息的训练样本,学习训练特征提取器和分类器参数,再对未知类别的样本测试判断其辐射源属性^[2-6]。通信辐射源个体识别的关键在于提取出辐射源的有效特征,利用残差网络可以解决传统识别方法中人工提取特征效率低下的问题,并保持较高的识别正确率^[7-10]。同时,结合输入数据的特性,可对残差网络的结构进行适应性调整,以进一步提高识别的效果^[11-12]。

然而实际应用中,信号采集方无法主动控制信号背景的电磁环境或被采辐射源,使得目标电磁信号质量差、难截获。在这种非合作条件下,可标注和可训练的数据有限,容易造成过拟合导致分类精度下降,难以形成有效的识别模型,因此需要结合数据增强和小样本识别方法,对通信辐射源个体目标进行识别^[13-17]。Liu 等^[18]针对辐射源个体识别可能会受到不稳定特征干扰的问题,利用数据增强方法在训练网络时对数据进行扩充,降低预处理的复杂度,同时抑制功率变化、频率偏移、相位偏移和信道噪声的干扰。Zhou 等^[19]将生成对抗网络引入电磁信号分类领域,利用生成对抗网络的样本增强能力构建半监督学习框架,直接处理电磁信号的 IQ 数据,一定程度上解决了电磁信号类型分类和辐射源个体识别中的过拟合问题。一个神经网络若能够对不同状态下的目标进行稳健的分类,就被称为具有不变性的属性,更具体地说,卷积神经网络(CNN)对移位、

旋转、缩放、翻转等操作具有不变性,这是数据增强的前提。为解决过拟合问题,可以采用数据增强的方式,通过少量可用的信号样本生成更多的样本,对训练样本进行扩充。

同时,针对数据不易获取导致模型训练难、泛化性差的问题,可采用在资源充足环境中学到的知识辅助另一领域的学习策略,即迁移学习的思想。大部分数据或任务都存在相关性,因此迁移学习将某个领域或任务上学习到的知识或模式应用到相关的领域或问题中,把训练好的模型参数(也可理解为模型学到的知识)分享给新模型,从而避免网络从零学习,加快并优化模型的学习效率^[20-21]。Feng 等^[22]利用迁移学习方法筛选源域与目标域不同的部分,使源域的分布向目标域分布靠近,生成能够支撑后续分类方法的新数据集,解决了复杂电磁环境所导致的雷达辐射源目标域样本标签不足的问题。Kuzdeba 等^[23]针对环境、频道、调试样式、信号类型等因素导致的辐射源信号源域与目标域分布存在差异和样本标签缺失的问题,通过对网络模型参数的迁移,实现对不同辐射源的个体识别。Liu 等^[24]针对辐射源细微特征会随着时间、地点和条件的不同而变化,继而使得训练样本和测试样本分布不同的问题,通过迁移学习有效利用和转移已标记源域数据中的知识,提高了通信辐射源的个体识别性能。由此可见,迁移学习可以更好地探索数据结构信息,将有价值的知识从源域转移到目标域,在目标域样本不足以支撑模型训练的条件下,提高识别正确率。

针对小样本条件下产生 OFDM 信号通信辐射源的目标识别问题,提出了基于相位、时域翻转的数据增强和源领域实例迁移的方法,通过翻转的数据增强方法扩充数据集,并引入迁移学习以强化识别模型的泛化能力,提高了个体目标的识别准确率。

1 小样本 OFDM 目标增强识别方法

以通信辐射源产生的 OFDM 信号为研究对象,研究在小样本情况下的通信辐射源目标识别问题,实验数据来源于最易获取的手机 OFDM 信号,通过判断当前发射 OFDM 信号的手机属于华为畅享 Z、小米 Play4 或 vivo Y70s 等中的哪个型号,进一步判定手机个体是属于 5 部华为畅享 Z 或是 5 部小米 Play4 手机中的哪一部。对手机的个体识别有助于

识别不法分子在频繁更换用户识别(SIM)卡的情况下使用的手机,进而对其身份进行判别,在公共安全管理方面有一定的应用价值。同时,手机的个体识别方法在同样使用 OFDM 技术的无人机、数字广播、通信电台等领域中存在一定的共通性。

图 1 给出了基于迁移学习的小样本 OFDM 目标增强识别方法的总体流程。其中,(1, 2) 表示步长,即每次卷积后,卷积核在纵向移动 1 个位置,横向移动 2 个位置;1×7 和 3×3 为卷积核的尺寸;64 和 128 为该层输出的通道数,即卷积核的个数;全连

接层中的 5 表示输出的维度,即识别模型最终输出一个 5 维向量。首先通过数据预处理,对预先采集的手机 OFDM 信号进行分段筛选、归一化和双通道数据提取;其次,根据 OFDM 信号多载波的特点,修改卷积核结构,对残差网络进行适应性调整;再次,利用数据增强的方法,对数据样本进行扩充;最后,在上述实验基础上采用迁移学习方法,利用源域数据训练出旧模型,并使用旧模型的参数初始化新模型,从而构建目标域识别模型,完成目标识别任务,最终达到知识迁移的目的。

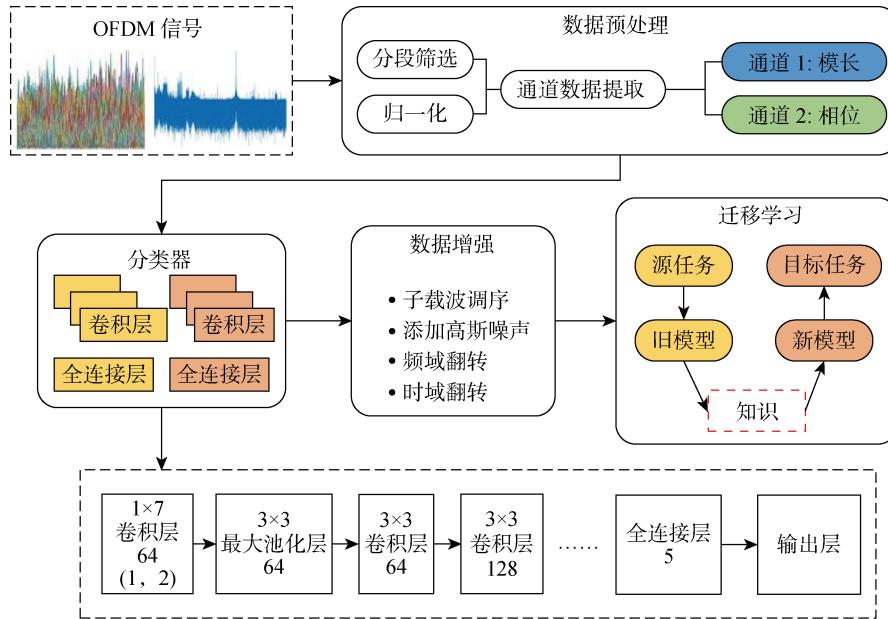


图 1 OFDM 信号目标识别方法总体流程

Fig. 1 Overall process of OFDM target identification method

1.1 OFDM 信号预处理

在对 OFDM 信号的采集中,每个数据文件采集时长 100 ms。如图 2 所示,每 1 ms 时长的数据包括 14 个 OFDM 符号和 1 个时隙号,数据分两个时隙传出,14 个 OFDM 符号依次为 3 个有效信号、1 个参考信号、6 个有效信号、1 个参考信号、3 个有效信号。每个 OFDM 符号包含 108 个子载波,每个子载波由 IQ 两路表示(2 个 short 数据类型)。

数据预处理分为数据分段筛选、归一化和双通道数据生成 3 部分。首先对每 100 ms 数据进行分割,每个数据文件中的信号分成有效信号、参考信号、时隙,选取其中有效信号;然后,由于辐射源个体指纹特征与信号的发射功率无关,为避免信号功率差异造成影响,对数据样本进行归一化处理;最后,将处理后的每 100 ms 数据分别按频谱图、IQ 两路实部和虚部加虚部、IQ 两路模长单通道和模长加相

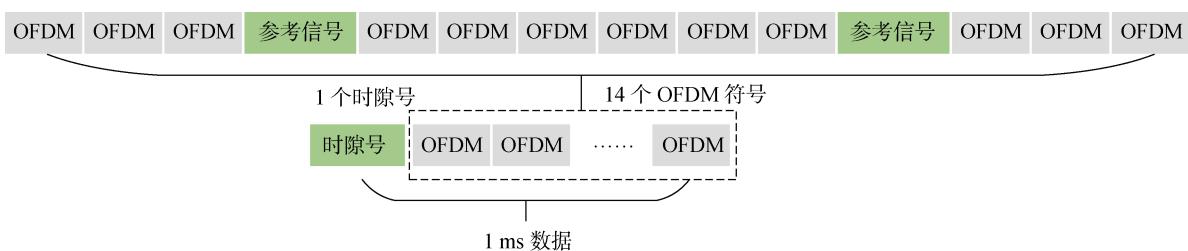


图 2 OFDM 信号数据结构示意

Fig. 2 Data structure of OFDM signal

位双通道共 5 种方式,各生成一个信号数据样本.

1.2 基于适应性调整的残差网络分类方法

残差网络(ResNet)是一种卷积神经网络,通过使用残差模块,可以解决卷积神经网络深度增加引起的性能退化问题.其包含一个新的网络块,网络块输入为 x ,输出为 $Q(x)$,这个网络块将输入特征 x 映射为 $Q(x)-x$,将 $Q(x)-x$ 记作 $F(x)$,即该网络块计算原映射 $Q(x)$ 与输入特征 x 的差值 $F(x)$,称作“使得该网络块学习原网络块 $Q(x)$ 与输入特征 x 的残差”,网络块结构如图 3 所示.其中,ReLU 为修正线性单元.

图 3 所示为两个权重层叠加而成的网络块完成从输入特征 x 到残差 $F(x)$ 的映射,并将 $F(x)$ 与右侧的短路链接进行元素级别的加法操作,最终该网络块输出为 $F(x)+x$,即图 3 中通过所有权重层后的输出仍为 $Q(x)$.

残差块结构不再让权重层只输出最终的特征图,而是让权重层输出最终特征图和输入特征的差值 $F(x)$,再将 $F(x)$ 与输入特征 x 进行元素级别加法操作得到最终特征图.图 3 的结构可表示为

$$y = \sigma(F(x, \{W_i\}) + x) \quad (1)$$

式中: $F = W_2\sigma(W_1x)$, σ 为修正线性单元(ReLU); W_i 为第 i 个权重层的权重矩阵.在完成 $F(x)$ 和 x 的元素加法后,图 3 中还进行了 ReLU 操作,即结构的最终输出为 $\sigma(Q(x))$.

以 ResNet-18(17 个卷积层和 1 个全连接层的残差网络)作为基础模型,其结构根据预处理后的数

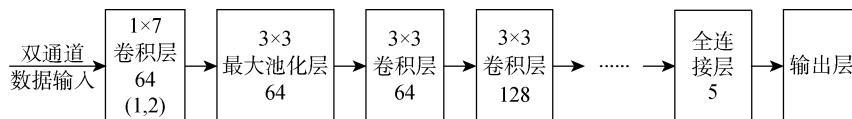


图 4 双通道输入下的残差网络结构

Fig. 4 Residual network structure with dual channel input

损失函数用来判定预测值和真实值的接近程度,有助于优化神经网络的参数,因此采用交叉熵作为损失函数,衡量实际输出与期望输出的差值.此外,通过 softmax 分类器,让分类预测值的和为 1. 损失函数定义如下:

$$\text{Loss}(p, q) = - \sum p(x) \log q(x) \quad (2)$$

式中: p 为标签值; q 为预测值.

梯度下降法(SGD)是机器学习中常用优化方法,采用小批量 SGD 方法,提升训练速度,提高内存利用率并减少迭代次数. SGD 优化方法设置动量参数为 0.9,学习速率为 0.01,批量大小为 16,训练迭

据进行调整. OFDM 信号数据被预处理为 3 种形式:①三通道的二维像素点的形式,对于这种数据形式,往往使用卷积神经网络建立模型;②单通道一维数据形式,保存的数据为完整的 IQ 信号模长;③双通道二维数据形式,增加了 I 路信号和 Q 路信号之间的相位信息,最大化保留了对分类有用的信息.对于后两种数据形式,首先需要调整网络输入层,将原本支持彩色图像 RGB 三通道的残差网络输入层修改为能支持以幅值和相位双通道数据作为输入,同时对前两个通道的权重进行拷贝,保证初始化权重与残差网络一致.然后,针对 OFDM 符号包含 108 子载波的特殊性质,对网络结构进行适应性调整,优化残差网络特征提取的方式,将原第一卷积层的卷积核由 7×7 降维至 1×7 ,使其更加关注同一子载波所展现的特征.最终确定残差网络结构如图 4 所示.

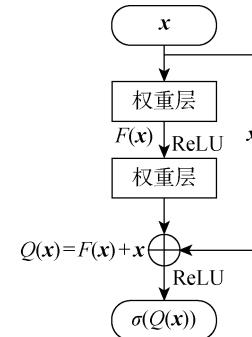


图 3 残差网络块结构

Fig. 3 Block structure of residual network

代次数为 100.

1.3 基于相位域和时域翻转的数据增强方法

为了在小样本条件下对辐射源信号进行个体识别,需要获得更多的样本数据,因此对现有的数据集进行微小的改变,如旋转、移位、翻转等,以对样本数据进行增强.针对 OFDM 信号的时频域特征,结合信号的周期性特征,提出一种在相位域和时域上翻转来进行数据增强的方法.

在相位域上,Hilbert 变换是信号处理中一种常用的手段,通过对原信号的相位反转,展现出信号不同的角度.采用 Hilbert 变换的方法,对信号进行卷

积来构建目标的时频解析信号,从而实现增强效果.

假设现有信号 $s(t)$,则定义信号 $s(t)$ 的 Hilbert 变换为

$$H(s(t)) = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{s(\tau)}{t - \tau} d\tau \quad (3)$$

由上式可知, $H(s(t))$ 是 $s(t)$ 和 $1/(\pi t)$ 的卷积. 通过查表求解, 求得:

$$H(s(t)) = -j \operatorname{sgn}(\omega) = \begin{cases} -j, & \omega > 0 \\ +j, & \omega < 0 \end{cases} \quad (4)$$

式中: j 为虚数单位; ω 为角频率.

因此, $|H(s(t))| = 1$, 令:

$$H(s(t)) = |H(s(t))| e^{j\varphi(\omega)} = \begin{cases} -j, & \omega > 0 \\ +j, & \omega < 0 \end{cases}$$

引入欧拉公式 $e^{j\varphi(\omega)} = \cos \omega_0 n + j \sin \omega_0 n$, 由欧拉公式可知, 当 $\cos \omega_0 n + j \sin \omega_0 n = -j$ 时, $\omega_0 n = -\pi/2$, 即 $\varphi(\omega) = -\pi/2 (\omega > 0)$. 同理 $\varphi(\omega) = \pi/2 (\omega < 0)$, 整理可得:

$$\varphi(\omega) = \begin{cases} -\pi/2, & \omega > 0 \\ \pi/2, & \omega < 0 \end{cases} \quad (5)$$

由上式可知, 当频率大于 0 时, 相位向左移 90° , 反之, 向右移 90° , 因而实现了在相位域上的信号翻转.

在时域上, 针对信号具有周期性特征, 对 100 ms 原始信号数据中每个子载波所包含的 1 200 个 OFDM 有效信号进行水平翻转, 并将翻转后的子载波重新组合成包含 108 子载波的 OFDM 信号, 形成新的训练样本, 扩充训练集, 提升整体性能, 从而达到数据增强目的.

1.4 基于源领域实例的迁移学习方法

电磁信号难以截获, 导致采集的信号较难覆盖数量繁多的辐射源目标, 因此当面对新目标信号出现时, 需要对已有的个体识别模型进行迁移. 为了更快实现模型迁移, 达到较好的识别效果, 通常需要大量的标注数据, 在小样本条件下, 充分利用已有的标注数据改进迁移模型的学习效果是必要的. 因此, 提出一种通过源领域数据进行基于实例的迁移学习方法.

采集同品牌同型号的 5 部手机样本数据, 在拟定分类识别方法下完成模型训练. 在出现了不同品牌或同品牌同型号的新手机样本后, 利用已训练完成的模型, 初始化新手机识别任务的模型参数, 即从源领域中选出与目标域相似的数据作为新任务预训练模型的训练集. 因此, 新旧识别任务的数据来源有一定相似性, 相当于扩充了新任务训练集, 充分利用了电磁信号数据特征. 该方法提高了模型的鲁棒性、

加快了网络参数拟合速度, 能够更快达到较好的识别准确率.

如图 5 所示, 利用同源的旧数据在共享网络上训练出旧模型, 再利用旧模型的模型参数初始化目标任务的训练, 从而达到知识迁移的目的.

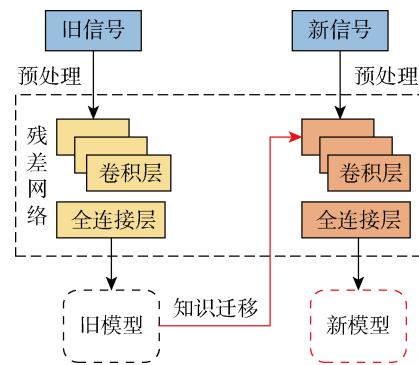


图 5 迁移学习方法架构

Fig. 5 Architecture of transfer learning method

2 实验

实验数据采集自共用一张 SIM 卡的手机个体目标的联通 4G OFDM 信号, 共有 5 个品牌的 30 部手机, 且每个品牌下的手机型号相同. 随机选取其中 5 部手机作为目标域样本, 包含 2 部华为、2 部 iQOO 和 1 部小米, 每部手机为识别模型中的一类, 各部手机有效信号样本数分别为 62、54、60、60、49, 将 5 部手机的信号样本按照 4:1 划分为训练集和验证集, 用于训练实验中进行适应性调整后的残差网络模型. 利用剩余手机目标数据构建 2 个源域, 每个源域 5 部同品牌同型号手机, 每部手机为识别模型中的一类, 有效信号样本 40~60 个, 保持与目标域一致, 作为迁移学习旧模型的训练数据. 每组实验均重复训练 10 次, 计算平均识别准确率和标准差. 其中, 识别准确率定义为:

识别准确率 =

$$\frac{\text{识别正确的目标信号数量}}{\text{目标信号总数}} \quad (6)$$

实验通过对手机个体目标识别结果的对比, 依次分析不同数据输入方式、数据增强方法以及迁移学习方法对识别模型的影响, 从而研究小样本下 OFDM 通信辐射源目标识别的效果.

2.1 数据输入的影响

在数据预处理中将数据保存为单通道和双通道的形式, 单通道数据的维度为(108, 1200, 1), 双通道数据的维度为(108, 1200, 2). 分别用图像、单通道实部、双通道实部及虚部、单通道幅值和双通道幅

值及相位共 5 种输入方式的数据, 训练修改通道数后的残差网络, 实验结果如图 6。

如图 6 和表 1 所示, 对比 5 种数据输入方式: 以图像方式输入会导致不同子载波叠加相互影响, 效果最差, 平均识别准确率仅有 32.23%; 以实部、实部和虚部组合形式输入, 一定程度上损失了 IQ 两路信号的内在联系, 平均识别准确率约为 51%; 以幅值、幅值和相位组合形式输入, 平均识别准确率分别为 66.16%、67.28%. 以幅值和相位组合方式识别准确率最高, 这表明幅值和相位组合双通道方式不仅包含了信号的幅度和相位信息, 还最大程度保留 IQ 两路数据的内在联系。

在幅值和相位组合双通道输入的基础上, 调整了残差网络的结构, 以改变其特征提取的方式, 将卷积核降至一维, 同时修改步长, 与原残差网络进行对比实验, 实验结果如图 7 所示。

如图 7 和表 2 所示, 对比不同网络结构: 原 7×7 卷积核的网络结构平均识别准确率较低, 且波动较大难以快速收敛, 而调整后的卷积核大小为 1×7 , 平均识别准确率为 69.83%, 能够保持模型识别准确率较为平稳。这表明调整后的残差网络能够使模

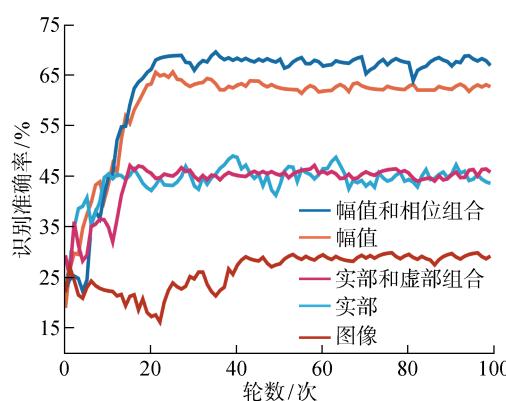


图 6 5 种数据输入方式的单次训练结果对比

Fig. 6 Comparison of single training results of 5 data input methods

表 1 5 种数据输入方式比较

Tab. 1 Comparison of 5 data input methods %

数据输入方式	平均识别准确率 ± 标准差
图像	32.23 ± 2.78
实部	51.39 ± 3.25
实部和虚部组合	51.57 ± 3.34
幅值	66.16 ± 3.45
幅值和相位组合	67.28 ± 2.80

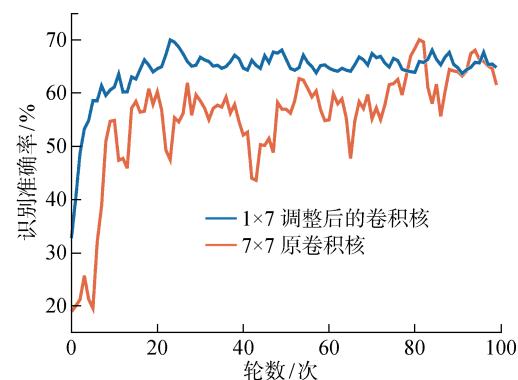


图 7 网络结构调整前后单次训练结果对比

Fig. 7 Comparison of single training results before and after network structure adjustment

表 2 网络结构调整前后比较

Tab. 2 Comparison before and after network structure adjustment %

卷积核结构	平均识别准确率 ± 标准差
7×7 原卷积核	67.28 ± 2.90
1×7 调整后卷积核	69.83 ± 1.48

型更加关注同一子载波所展现的特征, 模糊子载波间可能存在的干扰信息, 使得模型能够快速收敛, 提高识别准确率。

2.2 数据增强方法的对比

以上一节调整后的残差网络结果为基线, 进行 4 种数据增强方法效果对比实验: ① 子载波调序的数据增强, 生成 9 组 0~108 的随机序列, 调整各个原始样本中子载波的顺序, 扩充训练集为原来的 10 倍; ② 添加高斯噪声, 设定方差系数为 0.01. 在每一轮中, 随机为 1/4 的数据添加高斯噪声; ③ 相位域翻转, 将时域信号实部进行 Hilbert 变换, 构建解析信号, 将复数结果幅值和相位作为双通道输入; ④ 时域翻转, 对每一个训练集样本中所有子载波进行水平翻转, 合成新的样本, 扩充训练集为原来的 2 倍。训练结果如图 8。

如图 8 和表 3 所示, 4 类数据增强方法与不使用数据增强相比识别准确率增加 8%~9%, 有明显提升; 提出的基于相位域和时域翻转的数据增强方法取得了较好的效果, 其平均识别准确率分别为 78.48%、79.35%. 这表明采用相位域和时域翻转的数据增强方法构建的解析信号数据, 具有更好的特征表现能力, 使得模型更加稳定。同时, 也证明数据增强策略, 对小样本下的 OFDM 通信辐射源目标识别准确率有较大提升, 具有良好的效果。

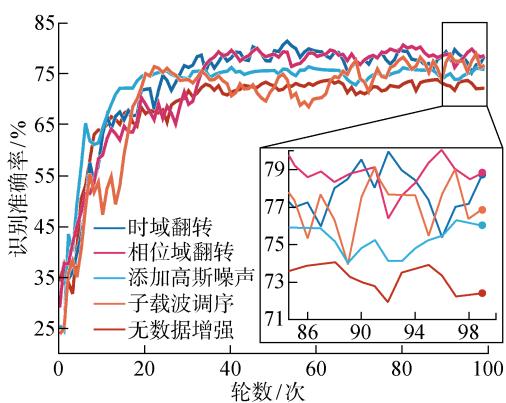


图 8 小样本数据增强单次训练结果对比

Fig. 8 Comparison of single training results of data augmentation methods for few-shot learning

表 3 小样本数据增强方法比较

Tab. 3 Comparison of data augmentation methods for few-shot learning

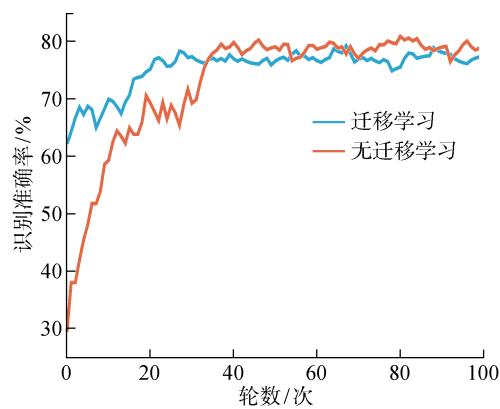
数据增强方法	平均识别准确率±标准差
无数据增强	69.83±1.48
子载波调序	77.30±2.24
添加高斯噪声	77.69±2.38
相位域翻转	78.48±2.14
时域翻转	79.35±1.26

2.3 迁移学习加入的作用

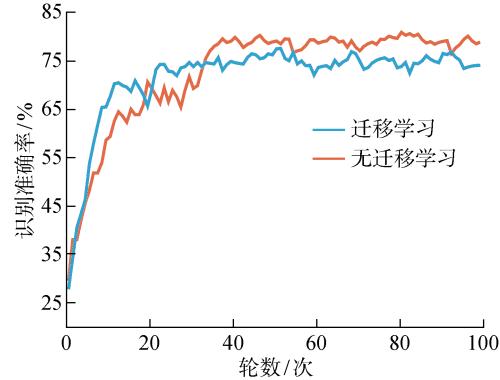
通过对比实验,研究模型加入迁移学习的效果,以上述实验的 5 部手机(包含华为、iqoo、小米)数据作为目标域,再利用剩余手机目标中 5 部小米同型号手机和 5 部 vivo 同型号手机的数据分别构建 2 个源域,用源域目标样本数据做预训练,生成 2 个源域识别模型,并在各自向目标域进行迁移时,使用源域模型的参数对目标域的模型训练进行初始化。

目标域和源域中存在一部分公共的特征,但也存在一定的差异,主要表现为:一是两类域中虽然包含了同品牌同型号的手机,但手机个体不同,如源域与目标域中的小米手机在硬件特征上有细微差异,使得两类域分布存在一定差异性,训练结果如图 9(a);二是两个域之间手机为不同品牌,这些手机由不同品牌厂家设计、生产、组装,从硬件上来看,两类域分布有较大的差异,训练结果如图 9(b)。这样构建源域和目标域的目的是让两者既保持了差异性,又避免了差异过大产生负迁移,因此可以很好地作为迁移学习的实验对象。

图 9(a)中,由于源域和目标域中均包含小米品牌手机,虽然手机个体不同,但是预训练模型能够较



(a) 无迁移学习和源域为 5 部小米手机



(b) 无迁移学习和源域为 5 部 vivo 手机

图 9 迁移学习单次训练结果对比

Fig. 9 Comparison of single transfer learning training results

好的区分目标域中其他品牌和小米品牌手机的区别,因此,预训练模型初始目标识别率较高。图 9(b)中,源域和目标域包含不同品牌的手机,预训练模型初始目标识别率与无迁移学习对照组保持一致,但其收敛速度更快。

如表 4 所示,两个不同源域的迁移学习识别准确率虽较无迁移学习对照组有所下降但相差不大,且目标识别率的波动较为稳定,这表明迁移学习的加入,提高了 OFDM 通信辐射源识别模型的泛化性和鲁棒性。同时,由图 9 所示,预训练后的模型较无迁移学习对照组收敛速度更快,说明迁移学习能够加快网络参数拟合速度,更快达到较好的识别准确率。

表 4 迁移学习加入前后的比较

Tab. 4 Comparison before and after adding transfer learning

迁移学习作用对比	平均识别准确率±标准差
无迁移学习	79.35±1.26
有迁移学习(源域为 5 部小米手机)	77.76±2.06
有迁移学习(源域为 5 部 vivo 手机)	76.60±1.94

3 结语

针对非合作条件下,通信辐射源信号数据稀缺难以有效进行目标识别的问题,利用双通道方式提取子载波信号复杂特征,采用翻转的数据增强方法扩充数据样本集,再基于适应性调整的残差网络和实例的迁移学习方法,对通信辐射源目标进行识别和模型构建,实现了小样本条件下通信辐射源的模型迁移和目标识别。实验结果表明,以幅值及相位双通道方式作为输入能更好地保留信号数据特征,结合相位域、时域翻转等数据增强方法,能够一定程度解决样本稀缺的问题,显著提升适应性调整后的残差网络的识别性能。此外,迁移学习方法能够加快网络参数拟合速度,利用少量数据快速构建可适应新目标的识别模型,在不降低分类性能的条件下,有效提高模型鲁棒性和泛化性。

在实际应用中,待识别辐射源目标不仅存在样本稀缺的问题,甚至没有任何数据,对这类未知辐射源目标的识别将是下一阶段的研究方向。

参考文献:

- [1] 徐晋凯,谢钧.辐射源识别技术发展研究[J].**信息技术与网络安全**,2021,40(10):1-7.
XU Jinkai, XIE Jun. Research on the development of specific emitter identification[J]. **Information Technology and Network Security**, 2021, 40(10): 1-7.
- [2] 张谦,王吉,唐泽宇,等.基于深度学习的通信电台个体识别技术[J].**电子信息对抗技术**,2021,36(2):36-40.
ZHANG Qian, WANG Ji, TANG Zeyu, et al. Individual identification technique of communication transmitters based on deep learning[J]. **Electronic Information Warfare Technology**, 2021, 36(2): 36-40.
- [3] 陈锐,雷迎科,李昕,等.基于IQ图特征的通信辐射源个体识别[J].**信号处理**,2021,37(1):120-125.
CHEN Yue, LEI Yingke, LI Xin, et al. Specific emitter identification of communication radiation source based on the characteristics IQ graph features [J]. **Journal of Signal Processing**, 2021, 37(1): 120-125.
- [4] 黄少驰,朱晓蕾.一种基于射频指纹的通信个体识别方法[J].**航天电子对抗**,2018,34(1):31-34.
HUANG Shaochi, ZHU Xiaolei. A communication individual recognition method based on radio frequency fingerprint [J]. **Aerospace Electronic Warfare**, 2018, 34(1): 31-34.
- [5] 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.
- [6] 李鹏,阮晓钢,朱晓庆,等.基于深度强化学习的区域化视觉导航方法[J].**上海交通大学学报**,2021,55(5):575-585.
LI Peng, RUAN Xiaogang, ZHU Xiaoqing, et al. A regionalization vision navigation method based on deep reinforcement learning[J]. **Journal of Shanghai Jiao Tong University**, 2021, 55(5): 575-585.
- [7] 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**. Las Vegas, NV, USA: IEEE, 2016: 770-778.
- [8] 陈浩,杨俊安,刘辉.基于深度残差适配网络的通信辐射源个体识别[J].**系统工程与电子技术**,2021,43(3):603-609.
CHEN Hao, YANG Junan, LIU Hui. Communication transmitter individual identification based on deep residual adaptation network[J]. **Systems Engineering and Electronics**, 2021, 43(3): 603-609.
- [9] PAN Y W, YANG S H, PENG H, et al. Specific emitter identification based on deep residual networks [J]. **IEEE Access**, 2019, 7: 54425-54434.
- [10] 曲凌志,杨俊安,刘辉,等.一种基于复数残差网络的通信辐射源个体识别方法[J].**信号处理**,2021,37(1):95-103.
QU Lingzhi, YANG Junan, LIU Hui, et al. A method of personal identification of communication radiation source based on complex-valued residual network[J]. **Journal of Signal Processing**, 2021, 37(1): 95-103.
- [11] HE T, ZHANG Z, ZHANG H, et al. Bag of tricks for image classification with convolutional neural networks[C]//**2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition**. Long Beach, CA, USA: IEEE, 2019: 558-567.
- [12] 李辰,李建勋.卷积神经网络的正交性特征提取方法及其应用[J].**上海交通大学学报**,2021,55(10):1320-1329.
LI Chen, LI Jianxun. Orthogonal features extraction method and its application in convolution neural network[J]. **Journal of Shanghai Jiao Tong University**, 2021, 55(10): 1320-1329.
- [13] WANG Y Q, YAO Q M, KWOK J T, et al. Generalizing from a few examples[J]. **ACM Computing Surveys**, 2021, 53(3): 1-34.
- [14] 方章闻,张金艺,李科,等.小样本条件下的通信辐

- 射源半监督特征提取[J]. 系统工程与电子技术, 2020, 42(10): 2381-2389.
- FANG Zhangwen, ZHANG Jinyi, LI Ke, et al. Semi-supervised feature extraction of communication emitter under small sample condition[J]. **Systems Engineering and Electronics**, 2020, 42(10): 2381-2389.
- [15] ZHOU H J, BAI J, WANG Y R, et al. Few-shot electromagnetic signal classification: A data union augmentation method [J/OL]. (2021-09-15) [2022-01-05]. <https://doi.org/10.1016/j.cja.2021.07.014>.
- [16] ZHANG W, JIANG L, DING C Z, et al. Small sample identification for specific emitter based on adversarial embedded networks [C/OL]. (2021-09-30) [2022-01-06]. https://doi.org/10.1007/978-3-030-87358-5_18.
- [17] 何新林, 戚宗峰, 李建勋. 基于隐变量后验生成对抗网络的不平衡学习[J]. 上海交通大学学报, 2021, 55(5): 557-565.
- HE Xinlin, QI Zongfeng, LI Jianxun. Unbalanced learning of generative adversarial network based on latent posterior[J]. **Journal of Shanghai Jiao Tong University**, 2021, 55(5): 557-565.
- [18] LIU Y H, XU H, QI Z S, et al. Specific emitter identification against unreliable features interference based on time-series classification network structure [J]. **IEEE Access**, 2020, 8: 200194-200208.
- [19] ZHOU H J, JIAO L C, ZHENG S L, et al. Generative adversarial network-based electromagnetic signal classification: A semi-supervised learning framework [J]. **China Communications**, 2020, 17(10): 157-169.
- [20] RIBANI R, MARENCONI M. A survey of transfer learning for convolutional neural networks[C]// **2019 32nd SIBGRAPI Conference on Graphics, Patterns and Images Tutorials**. Rio de Janeiro, Brazil: IEEE, 2019: 47-57.
- [21] WEISS K, KHOSHGOFTAAR T M, WANG D D. A survey of transfer learning[J]. **Journal of Big Data**, 2016, 3(1): 1-40.
- [22] FENG Y T, CHENG Y J, WANG G L, et al. Radar emitter identification under transfer learning and online learning[J]. **Information**, 2019, 11(1): 15.
- [23] KUZDEBA S, ROBINSON J, CARMACK J. Transfer learning with radio frequency signals[C]// **2021 IEEE 18th Annual Consumer Communications & Networking Conference**. Las Vegas, NV, USA: IEEE, 2021: 1-9.
- [24] LIU H, HU P J, LIU Z. Communication specific emitter identification based on transfer learning[J]. **Journal of Physics: Conference Series**, 2020, 1626(1): 012027.

(本文编辑:孙伟)