

DOI:10.19651/j.cnki.emt.2108520

基于深度残差收缩网络的辐射源个体识别方法*

唐震^{1,2} 乔晓强² 张涛² 苏健¹ 杨小蒙^{2,3}(1.南京信息工程大学计算机与软件学院 南京 210044; 2.国防科技大学第六十三研究所 南京 210007;
3.南京信息工程大学电子与信息工程学院 南京 210044)

摘要: 辐射源个体识别是电子对抗领域中的重要技术,通过识别设备间不同细微特征从而达到区分非法设备与合法设备的目的。针对辐射源个体间指纹特征差异细微且在噪声干扰下提取特征较少的问题,提出了一种基于深度残差收缩网络的辐射源个体识别方法。该方法首先将 I/Q 图特征数据进行拼接,利用数据增强技术进行样本扩充,进而构建了深度残差收缩网络识别模型,最后对构建的模型进行 ADS-B 辐射源个体识别训练并进行识别效果评估。仿真结果表明,本文构建的深度残差收缩网络通过消除数据噪声的优势,对数据增强后的 20 类 ADS-B 辐射源个体在 0 dB 的低信噪比条件下总体识别准确率达到 98.2%,其性能较相同层数的 Resnet 网络提高了 1.3%,并明显优于现有其他方法。

关键词: 深度残差收缩网络;辐射源个体识别;特征拼接;数据增强;软阈值化

中图分类号: TP183;TN92 **文献标识码:** A **国家标准学科分类代码:** 510.4010

Individual radiator identification method based on deep residual shrinkage network

Tang Zhen^{1,2} Qiao Xiaoqiang² Zhang Tao² Su Jian¹ Yang Xiaomeng^{2,3}

(1. School of Computer and Software, Nanjing University of Information Science and Technology, Nanjing 210044, China;

2. The 63rd Research Institute of National University of Defense Technology, Nanjing 210007, China;

3. School of Electronic and Information Engineering, Nanjing University of Information Science and Technology, Nanjing 210044, China)

Abstract: The identification of individual radiation sources is an important technology in the field of electronic countermeasures. By identifying different subtle features between devices, the purpose of distinguishing illegal devices from legal devices is achieved. Aiming at the problem of subtle differences in fingerprint features between individual radiation sources and fewer features extracted under noise interference, this paper proposes a method of identifying individual radiation sources based on a deep residual shrinkage network. This method first splices the feature data of the I/Q map, uses data enhancement technology to expand the sample, and then constructs a deep residual shrinkage network recognition model. Finally the constructed model is trained for individual ADS-B radiation source recognition and the recognition effect is evaluated. The simulation results show that the deep residual shrinkage network constructed in this paper uses the advantage of eliminating data noise, and the overall recognition accuracy of the 20 types of ADS-B radiation source individuals after data enhancement has reached 98.2% when the SNR is as low as 0 dB. Compared with the Resnet network with the same number of layers, its performance is improved by 1.3%, and it is significantly better than other existing methods.

Keywords: depth residual shrinkage network; individual identification of radiation sources; feature splicing; data enhancement; soft-thresholding

0 引言

随着无线通信和物联网技术的不断发展,通信系统中

无线设备的数量迅速增加。无线设备由于设备公差而生成的细微特征具有难以克隆的物理特征,这种各个设备间产生的不同细微特征被称之为射频指纹,使用射频指纹区分

收稿日期:2021-12-06

* 基金项目:国家自然科学基金(61801496,61801497)、军委科技委基础加强计划领域基金(2019-JCJQ-JJ-221)项目资助

非法设备与合法设备是保护通信系统安全的一种新的物理层方法。辐射源个体识别 (specific emitter identification, SEI), 是提取同类辐射源信号中的射频指纹来识别不同辐射源个体的过程^[1]。由于射频指纹来自于发射机电子元件的固有差异, 即使是同一批次生产的不同辐射源电路之间也具有细微差异, 具有不可避免且难以伪造的优点, 因此 SEI 技术被广泛应用于无线通信安全认证、无线电监测、电磁环境感知、信息作战等领域。

辐射源个体识别技术主要研究辐射源信号的暂态特征和稳态特征。对于暂态特征的提取通常使用分形理论^[2]和小波变换^[3], 对稳态特征的提取则多借助双谱分析^[4]和时频分析^[5]。由于手工提取的暂态与稳态特征存在耗时、低效和可移植性低等问题, 逐渐被研究人员所舍弃。而自动提取特征和分类识别结合, 采用模型自主学习, 实现特征自动提取以及辐射源分类, 大大提高了识别效率。陈小惠等^[6]将辐射源信号的复杂度特征放入改进后的极限学习机 (ELM) 中训练, 能准确的识别出信号的类型。而石丹等^[7]则将支持向量机 (support vector machine, SVM) 和人工神经网络 (artificial neural network, ANN) 应用到辐射源个体识别中, 并指出了 SVM 更具优势。但仍然存在不足: 随着样本数量的增加, 训练时间加长, SVM 的分类效率降低。近年来, 深度学习的快速发展为辐射源个体识别提供了新的处理思路^[8]。其中 CNN 神经网络^[9]经过多年的发展已经逐渐成熟, 在辐射源个体识别领域与 CNN 神经网络经常搭配使用的特征有经验模态分解^[10]和星座图特征^[11]等, 并且都能得到很好的识别效果。文献 [12] 使用深度残差网络 (residual network, Resnet) 挖掘 I/Q 信号的联合深度特征, 实现了辐射源个体信号的自动识别, 并获得了较好的识别准确率。Wang 等^[13]通过深度复数网络 (deep complex networks, DCN), 将通信辐射源个体的射频指纹特征提取与识别过程相结合, 建立了

适合无线通信的端到端深度学习模型, 大大提高了通信辐射源个体的识别精度。徐雄^[14]根据 ADS-B 样本特点设计了一种改进型的 Alexnet 网络, 在提高识别率的基础上同时缩减了训练时间。但以上方法都忽视了在实际通信情况下, 采集的数据样本有限且噪声对辐射源个体识别的影响十分巨大, 在低信噪比下往往难以获得较高的识别精度。因此寻找一种快速且有效的识别算法就成为了辐射源个体识别的关键, 本文提出了一种基于深度残差收缩网络的辐射源个体识别方法, 首先采用 IQ 图特征拼接进行预处理, 之后利用数据增强技术扩充样本, 最后, 将注意力机制、软阈值函数与残差网络结合, 构建深度残差收缩网络对数据增强后的 IQ 波形图进行分类。仿真实验进一步验证了本文构建的深度残差收缩网络具备利用软阈值化消除数据噪声的优势, 可提升 ADS-B 辐射源个体的有效辨识和识别精度。

1 系统设计

如图 1 所示, 系统总体流程如下。

1) 数据预处理。首先对采集到的 ADS-B 信号进行归一化, 然后将一维数据转变为二维的 I/Q 图像, 最后根据采样点与信号值进行特征拼接。

2) 数据增强。通过亮度增强、对比度增强、随机翻转等方法进行数据增强, 进行样本扩充, 最后将扩充后的样本数据划分为训练集与测试集。

3) 模型构建。以深度残差网络架构为基础, 融合注意力机制算法和软阈值函数构建深度残差收缩模块, 然后经过多个残差收缩模块以及卷积层、全局均值池化以及全连接输出层等, 最终构建完整的深度残差收缩网络模型。

4) 分类识别。将训练集输入到深度残差收缩网络模型中进行训练, 训练完毕后利用测试集样本对训练后的网络模型进行辐射源个体识别测试, 得到分类识别结果。

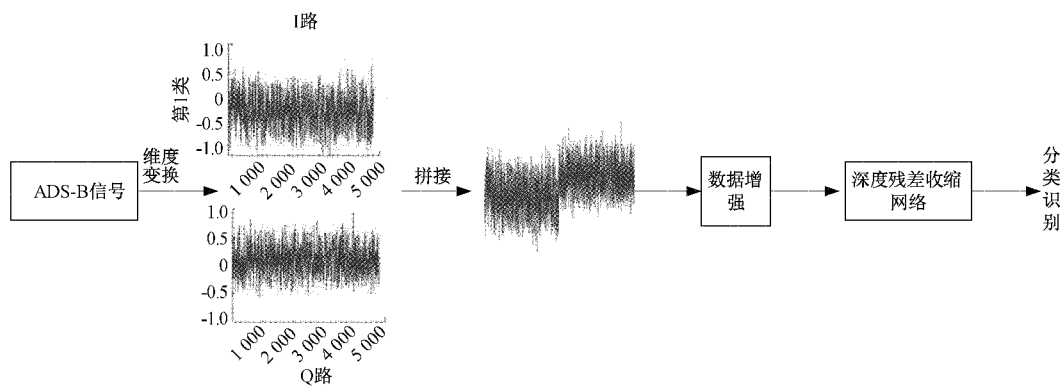


图 1 系统框图

2 数据预处理与数据增强

2.1 维度变换

为了降低数据幅度对特征的影响, 本文首先对 ADS-B 数据进行了归一化处理, 得到幅度最大值为 1 的 I、Q 数

据, 其次对归一化的 IQ 数据每个截取 4 800 个点为一个数据样本, 最后将截取的一维数据点变成二维的波形图, 其中横轴为时间序列轴, 纵轴为一维序列对应的值。图 2 所示为两类辐射源信号的部分 IQ 数据波形图。通过观察 IQ 数据的波形, 观察到当 I 路数据变化的时候, Q 路数据会出

现对应的变化,这种波形的变化,存在两个特征:重复性与个体特异性。




图 2 两类信号的部分 I 路和 Q 路

2.2 特征拼接

通过对 IQ 数据的观察发现,I 路数据和 Q 路数据会对应的变化,在同一标签数据中存在重复性,不同标签数据中存在差异性。针对重复性与个体特异性的特征,为了更好地兼顾和综合 I 路和 Q 路信号的特征,本文采用拼接的方式将 I、Q 路信号值-采样点拼接成一张图像,形成 I/Q 拼接图,第 1 类中第 1 个数据的拼接图如图 3(a)所示,第 2 类中第 1 个数据的拼接图如图 3(b)所示。




图 3 IQ 数据拼接

2.3 数据增强

本文选取 20 类 ADS-B 信号样本作为实验对象,由于每类 ADS-B 信号样本数为 113~144 条不等,数据总样本数量较少。为了丰富训练集样本数据,本文使用有监督的数据增强方法进行样本数据扩增,具体通过亮度增强、对比度增强、水平反转和随机翻转等方法生成更多等价有效的数据。以第 1 类数据的第 1 个样本为例,经过上述方法后的效果图如图 4 所示。以上采用的方法均不会产生失真和降低图片质量,经过数据增强,最终总样本数据量扩充到原数据量的五倍。




图 4 数据增强

3 深度残差收缩网络设计

本文使用的深度残差收缩网络 (deep residual shrinkage networks, DRSN)以深度残差网络为基础,融合注意力机制算法和软阈值函数可以更有效地去除与噪声相关的特征,并且可以自动学习获取阈值^[15]。

为了提取输入图像中的重要特征信息,抑制其他无关或相关性较小的信息。注意力机制算法^[16]在原先网络结构上嵌入一个子网络通过压缩、激励和加权 3 个操作来实现,其结构如图 5 所示。




图 5 注意力机制结构

其中,压缩操作 $F_{sq}(\cdot)$ 是将图像的所有二维特征压缩成实数,使其具备全局感受野。激励操作 $F_{ex}(\cdot, w)$ 为所有特征生成权重。加权操作 $F_{scale}(\cdot)$ 则将新生成的权重逐一加权到原先特征之上,从而达到分辨特征中重要信息与无关信息的目的。

噪声对辐射源个体识别的影响十分巨大,软阈值函数通常应用在信号降噪领域中^[17],来增强对特征的提取能力。将深度神经网络与软阈值函数相结合,利用神经网络子网络自动选取阈值从而削弱噪声对识别任务的影响,避免了在传统小波降噪方法中阈值难以选取的问题。软阈值函数的原理是设定一个大于 0 的阈值,若输入数据的绝对值低于该阈值,则将此数据置为 0,反之将此数据向 0 进行收缩。其表达式为:

$$y = soft(x, T) = \begin{cases} x - T, & x > T \\ 0, & -T \leq x \leq T \\ x + T, & x < -T \end{cases} \quad (1)$$

式中: x 为输入特征, y 为输出特征, T 为阈值。

综上,在深度残差网络架构的基础上加入注意力机制算法以及软阈值函数,构建残差收缩模块 (residual

shrinkage block, RS-block), 如图6所示。残差收缩模块可以学习得到一组阈值, 通过注意力机制进行自动调

整, 不断提高噪声中提取重要特征和抑制无关特征的能力。

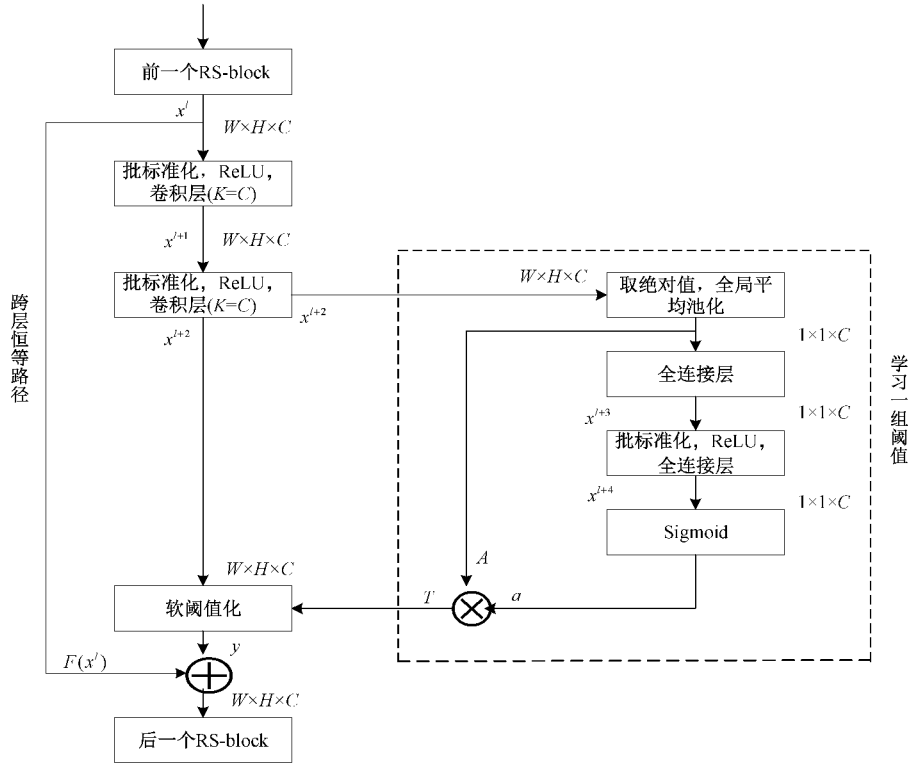


图6 RS-block 结构

在 RS-block 结构中, x^l 代表第 l 层卷积层的输入特征图, 尺寸大小为 $W \times H \times C$; $K = C$ 代表卷积核的个数与特征图的通道数相同; x^l 经过两层卷积隐藏层、批标准化和 ReLU 激活函数输出得到 x^{l+2} 。其表达式如下:

$$x^{l+1} = \text{ReLU}(\mathbf{W}^{l+1} x^l + \mathbf{b}^{l+1}) \quad (2)$$

$$x^{l+2} = \mathbf{W}^{l+2} \text{ReLU}(\mathbf{W}^{l+1} x^l + \mathbf{b}^{l+1}) + \mathbf{b}^{l+2} \quad (3)$$

式中: \mathbf{W}^{l+1} 、 \mathbf{W}^{l+2} 和 \mathbf{b}^{l+1} 、 \mathbf{b}^{l+2} 分别为权重向量和偏置向量。

构建的子网络目的是学习得到一组阈值, 首先对 x^{l+2} 进行取绝对值、全局平均池化操作, 得到一个一维向量 \mathbf{A} 。另外在第 2 条路径上对 x^{l+2} 进行取绝对值和全局均值池化操作, 随后通过两层全连接层、批标准化、ReLU 输出得到 x^{l+4} , 经过 Sigmoid 函数激活最终输出得到参数 a , $a \in (0, 1)$ 。阈值 T 则为两条路径输出结果相乘, 其阈值表达式如下:

$$\mathbf{A} = |x^{l+2}| \quad (4)$$

$$a = \frac{1}{1 + e^{-x^{l+4}}} \quad (5)$$

$$T = a \cdot \mathbf{A} = \frac{|x^{l+2}|}{1 + e^{-x^{l+4}}} \quad (6)$$

可以看出阈值始终为一个正数且保持在一个合理的范围内, 促使不同样本有不同的阈值。输入经过上式得到第 $l+1$ 卷积层的输出和阈值 T , 在此处经过软阈值化处理

得到输出结果 y 。其表达式为:

$$y = \begin{cases} x^{l+2} - T, & x^{l+2} > T \\ 0, & -T \leq x^{l+2} \leq T \\ x^{l+2} + T, & x^{l+2} < -T \end{cases} \quad (7)$$

跨层恒等路径的输出记为 $F(x^l)$, 则最后残差收缩模块的输出结果为 $F(x^l) + y$ 。本文设计的深度残差收缩网络由多个残差收缩模块构成, 整体的深度残差收缩网络结构设计如图7所示。其中, Input 代表输入的特征图, 宽度和高度为 224×224 , 通道数为 3。Conv 代表卷积层, 其卷积核大小为 3×3 。 K 为卷积核的个数, BN (batch normalization) 代表批归一化, ReLU 为激活函数, RS-block 为残差收缩模块, S 代表步长, Avgpool 代表全局平均池化, FC 为全连接层。样本输入到模型后, 首先经过 1 个卷积层和 BN 层对样本的底层特征进行嵌入, 随后经过 8 个残差收缩模块进行降噪处理及特征提取, 再经过全局平均池化、BN 和 ReLU 函数处理后, 特征图展开为一维向量被送入全连接层, 最终得到分类识别结果并输出。

基于 DRSN 模型复杂度的考虑, 本文使用了一些操作在避免模型出现过拟合现象的同时改善模型的分类精度和训练效率: 在 DRSN 整体结构中最后的全连接层引入 Dropout 作为正则化方法。设置 Dropout 比率为 0.5, 通过将神经元的输出按照指定概率置 0 来减少神经元的协同来防止过拟合。引入 BN 层对批量数据进行归一化处理。

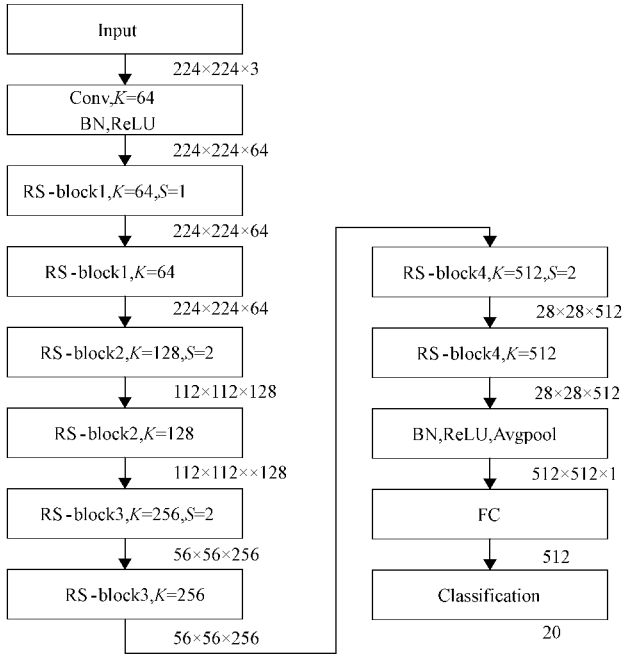


图 7 DRSN 整体结构

BN 层使网络减少过拟合,并使得训练具有快速收敛性。在每一个 RS-block 中卷积层采用文献[18]提出的正态分布初始化方法以及 L2 正则化。利用添加 L2 正则化项的交叉熵函数计算网络损失值,以此作为网络性能指标,表达式为:

$$L(y, \hat{y}) = -\frac{1}{m} \sum_m (y \ln \hat{y} + (1 - y) \ln(1 - \hat{y})) + \frac{\lambda}{2n} \sum_{i=0}^n \|\omega_i\|^2 \quad (8)$$

其中, m 为辐射源个体类别数, y 为真实值, \hat{y} 为网络模型预测值; $\frac{\lambda}{2n} \sum_{i=0}^n \|\omega_i\|^2$ 为正则化项,其作用是降低网络模型的复杂度,避免模型出现过拟合现象; λ 为正则化参数, ω 为模型权重参数,其作用是通过优化算法在反向传播时调整并更新网络权值。

本文设计了深度残差收缩网络、未采用残差收缩模块的残差网络和未使用残差模块的卷积神经网络处理 ADS-B 信号辐射源识别的任务。在后续的实验中,进行了模型收敛情况、识别率曲线、不同算法性能度量、和不同噪声对识别任务影响等多项对比,深度残差收缩网络的总体性能占优,因此本文最终采用深度残差收缩网络作为本任务的识别模型。

4 实验结果与分析

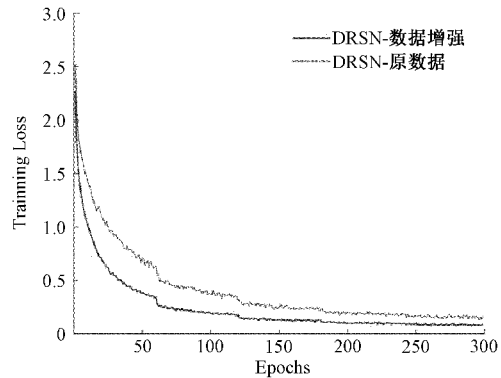
为了评估基于深度残差收缩神经网络的辐射源个体识别算法的可行性和有效性,本文使用采集的 20 类飞机的 ADS-B 辐射源数据作为实验对象,使用亮度增强、对比度增强、水平翻转和随机翻转等方法进行数据增强,最后

样本总量达到 12 960 条。训练集和测试集样本数量的比例设置为 9 : 1,即随机选择 11 664 个样本用于基于深度残差收缩网络辐射源个体识别模型的训练,剩余的 1 296 个样本用于训练后模型识别性能测试。本文利用 MATLAB2016a 软件对信号进行维度变化和特征拼接,数据增强以及样本划分依托 Python 及相关库进行。算法的训练和测试过程使用 Windows 平台下的 Pytorch 框架部署。在 GPU 加速的支持下,模型在 NVIDIA RTX A6000 上进行训练和测试。设置初始学习率为 0.000 1,每 50 个 Epoch 学习率下降 1/2。具体的实验参数设置如表 1 所示。

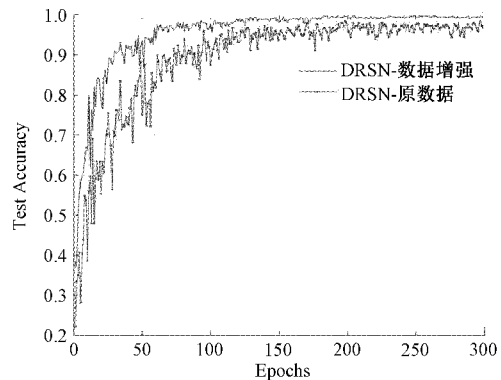
表 1 实验参数设置

初始学习率	优化方法	损失函数	batch	Epochs
0.000 1	Adam	CrossEntropyLoss	32	300

为了分析数据增强前后辐射源个体的识别性能,将原数据样本和数据增强后样本分别在 DRSN 模型下进行训练与测试,图 8 为两种样本数据的训练损失值和测试准确率随迭代次数变化的曲线。



(a) 数据增强前后的训练损失对比



(b) 数据增强前后的测试准确率对比

图 8 两种数据的训练损失与测试准确率对比

由图 8(a)可知基于数据增强后样本的 DRSN 模型训练损失值下降的更快且最终损失更低,在第 300 个 Epoch 的训练损失为 0.085 4,而基于原数据样本的训练损失为

0.1684。此外,图8(b)中可知由于数据增强后的样本数量增多,识别准确率曲线比原数据的识别准确率曲线波动幅度更小,同时原数据样本达到较高的识别准确率的基础上,使用了数据增强方法后,识别精度得到了进一步的提高,最终的识别准确率结果较原数据98.4%识别率提高了1.5%。

为了比较各类ADS-B信号的分类效果,DRSN模型识别20类ADS-B信号的混淆矩阵结果如图9所示。图9(a)为基于数据增强后样本识别结果的混淆矩阵,结果显示几乎所有类目标的识别准确率都达到100%,只有第16类信号与第13类信号出现了轻微混淆,识别率为98%。而图9(b)为基于原数据样本识别结果的混淆矩阵,其中显示原数据的20类ADS-B信号中第3、6、17类出现了较大混淆,三者的识别准确率均在95%以下,其余信号类别的识别率也都达到了100%,整体识别性能略低于前者。

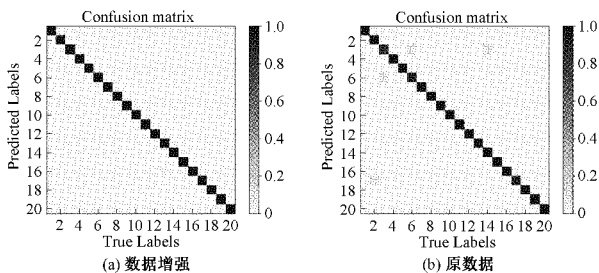


图9 两种数据的混淆矩阵

以上结果证明了数据增强技术对于小样本数据下辐射源个体识别起到优化效果,并且验证了DRSN在ADS-B辐射源个体识别中的有效性。

为进一步验证本文提出的DRSN模型对ADS-B辐射源个体识别性能,针对数据增强后的样本数据选取了文献[12]中的深度残差网络(Resnet)、文献[14]中的改进型Alexnet网络模型、卷积神经网络(CNN)和循环神经网络(recurrent neural networks, RNN)^[15]进行有针对性的对比实验。其中Resnet与DRSN网络层数相同且卷积核尺寸一致,其余模型不包含残差模块。在实测的20类目标样本的训练集上分别进行模型的训练,之后调用保存的训练好的模型对测试集进行识别分类,图10为各模型随迭代次数Epochs与测试集准确率Accuracy的结果图。通过观察不同模型在测试集上进行300轮训练迭代中的识别率变化评估其收敛情况,DRSN对测试集的识别率在绝大部分迭代过程中都保持了最高水平,对比Resnet能稳定的保持1.3%左右的领先优势,同时较其他模型波动幅度更小且收敛更快。而Resnet在模型迭代的过程中的识别率出现了较大的波动,位于DRSN之下。改进型的Alexnet略低于Resnet,CNN与RNN模型在收敛情况和收敛稳定后的识别率上与其他模型相比均存在较大差距。

在深度学习中评估模型的性能除了准确率Accuracy,通常还使用精确率 P 、召回率 R 以及调和平均数 $F1$ 值3

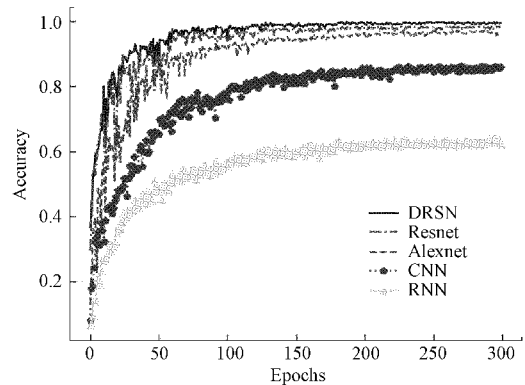


图10 不同模型随迭代次数的识别准确率对比

个参数。 P 表示预测所有正样本中判断正确的比例, R 表示预测正确的所有正样本占实际所有正样本的比例, $F1$ 值兼顾了分类模型的精确率和召回率,定义为模型精确率和召回率的调和平均数。通过比较测试样本集的预测精度来量化辐射源个体识别方法的性能。得到的各模型的识别性能结果如表2所示。

表2 网络性能比较

模型	准确率	精确率	召回率	F1值
DRSN	99.90	99.99	99.99	99.99
Resnet	98.64	98.69	98.64	98.66
改进型 Alexnet	97.36	97.40	97.35	97.37
CNN	86.50	86.99	86.49	86.74
RNN	64.19	64.42	63.73	64.07

通过与其他深度学习方法对比分析发现本文提出的DRSN模型在4个指标中都达到了最高水平。其准确率较Resnet、改进型Alexnet、CNN和RNN分别提高了1.26%、2.54%、13.4%和35.71%; $F1$ 值较其他4种模型分别提高了1.33%、2.62%、13.25%和35.92%。相比于卷积神经网络和循环神经网络,深度残差收缩网络在各项指标中更加突出。

为进一步验证识别算法的鲁棒性,在不同信噪比(signal-to-noise ratio, SNR)条件下进行识别实验的同时测试模型的抗噪声能力。采集的数据经MATLAB R2019a加高斯噪声并进行IQ拼接处理后,同样经过数据增强技术扩充至原数据的5倍。信号数据集中噪声信噪比范围为-10~10 dB,间隔为2 dB。该方法下的20类ADS-B信号,共142560个样本,同样按照9:1的比例划分训练数据和测试数据。各模型在不同信噪比上的识别准确率曲线如图11所示。

从图11可以看出,不同模型的识别准确率随着信噪比的提升而提高。本文提出的DRSN模型在不同的信噪比下的准确率均优于其他模型,并且识别率在信噪比为0 dB时达到98.2%,较相同层数的Resnet提高了1.3%,证




图 11 不同模型在不同信噪比下的识别准确率对比

明了该模型的有效性和鲁棒性。由此可见将软阈值函数、注意力机制与残差网络结合,可以有效提高神经网络对存在数据噪声的辐射源个体的分类识别精度。

5 结 论

本文提出了一种基于深度残差收缩网络的辐射源个体识别方法。首先采用 IQ 图特征拼接预处理并使用数据增强技术对预处理后的样本数量进行扩充。然后,整合残差网络、注意力机制和软阈值函数建立识别网络,通过自动学习的软阈值对残差模块的输出数据朝零进行收缩,达到去除数据噪声的目的;最后,基于构建的深度残差收缩网络对数据增强后的 IQ 波形图进行分类识别训练。实验表明,本文提出的辐射源分类识别模型对 20 类 ADS-B 辐射源个体在 0 dB 时的总体识别率达到了 98.2%,优于其他深度学习网络模型。

参考文献

- [1] 许敏,李博涵,王凯,等.特定辐射源个体识别算法研究[J].电子测量与仪器学报,2021,35(10):116-123.
- [2] 唐智灵,杨小牛,李建东.调制无线电信号的分形特征研究[J].物理学报,2011,60(5):556-562.
- [3] 龙英,何怡刚,张镇,等.基于信息熵和 Haar 小波变换的开关电流电路故障诊断新方法[J].仪器仪表学报,2015,36(3):701-711.
- [4] CAO R, CAO J W, MEI J P, et al. Radar emitter identification with bispectrum and hierarchical extreme learning machine [J]. Multimedia Tools and Applications, 2019, 78(20): 28953-28970.
- [5] ZHANG J, WANG F, DOBRE O A, et al. Specific emitter identification via Hilbert-Huang transform in single-hop and relaying scenarios [J]. IEEE Transactions on Information Forensics and Security, 2016, 11(6): 1192-1205.
- [6] 陈小惠,彭杰,薛毓楠.基于复杂度的通信辐射源目标识别方法[J].国外电子测量技术,2021,40(5):22-26.

- [7] 石丹,高攸纲.利用支持向量机识别电磁辐射源的方法(英文)[J].中国通信,2013,10(7):36-43.
- [8] 耿梦婕,张君毅.基于神经网络的辐射源个体识别技术[J].电子测量技术,2019,42(21):137-142.
- [9] TAN M, LE Q V. EfficientNet rethinking model scaling for convolutional neural Networks [C]. Proceedings of the 36th International Conference on Machine Learning, Long Beach: PMLR, 2019: 6105-6114.
- [10] LIANG J H, HUANG Z T, LI Z W. Method of empirical mode decomposition in specific emitter identification[J]. Wireless Personal Communications, 2017,96(3): 1-15.
- [11] 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.
- [12] 翁琳天然,彭进霖,何元,等.基于深度残差网络的 ADS-B 信号辐射源个体识别[J].航空兵器,2021,28(4):24-29.
- [13] WANG SH H, JIANG H L, FANG X F, et al. Radio frequency fingerprint identification based on deep complex residual network[J]. IEEE Access, 2020, 8: 204417-204424.
- [14] 徐雄.采用改进型 Alexnet 的辐射源目标个体识别方法[J].电讯技术,2018,58(6):625-630.
- [15] ZHAO M, ZHONG S, FU X, et al. Deep residual shrinkage networks for fault diagnosis [J]. IEEE Transactions on Industrial Informatics, 2020, 16(7): 4681-4690.
- [16] JIE H, LI S, GANG S, et al. Squeeze-and-excitation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(8):2011-2023.
- [17] ISOGAWA K, IDA T, SHIODERA T, et al. Deep shrinkage convolutional neural network for adaptive noise reduction[J]. IEEE Signal Processing Letters, 2017, 25(2): 224-228.
- [18] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. Proc. of the IEEE Conference on Computer Vision & Pattern Recognition, 2016: 770-778.
- [19] ZAREMBA W, SUTSKEVER I, VINVALS O. Recurrent neural network regularization [J]. Arxiv Preprint, 2014, Arxiv:1409.2329.

作者简介

唐震,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:903414103@qq.com

张涛(通信作者),工学博士,副研究员,主要研究方向为物理层安全、无线传感器网络、机器学习。

E-mail:ztcool@126.com