



研究与开发

基于时频和双谱特征融合的DA-ResNeXt50 射频指纹识别方法

陈梦迪¹, 张巍¹, 沈雷², 雷富强¹, 张佳飞²

(1. 杭州电子科技大学机械工程学院, 浙江 杭州 310018;

2. 杭州电子科技大学通信工程学院, 浙江 杭州 310018)

摘 要: 针对射频指纹识别中单一特征无法全面表示信号的完整性, 且类间特征差异较小从而限制识别准确率等问题, 提出了一种基于时频和双谱特征融合的DA-ResNeXt50 (ResNeXt50 with dense connection and AC-Block) 射频指纹识别方法。首先, 对采集到的不同设备的信号分别进行短时傅里叶变换 (short-time Fourier transform, STFT) 和双谱变换, 将得到的图像二值化处理并拼接, 综合利用两种变换分别在时频域和高阶统计特性上的优势, 更全面地提取和表征不同设备的射频指纹特征; 然后, 提出了DA-ResNeXt50网络模型, 借鉴密集连接思想, 使四层残差单元每一层都与前面所有层直接相连, 促进了特征的复用和传递, 能更好地捕捉类间细微差异; 最后, 使用非对称卷积模块 (asymmetric convolution block, ACBlock) 替换模型最后一层残差单元的3×3卷积, 可以有效地增加网络的感受野, 增强卷积核的骨架部分, 从而提高射频指纹识别性能。实验结果表明, 相较于使用单一特征提取方法, 提出的特征融合方法的性能有较大的提升, 改进后的模型与多种经典模型相比, 具有较高的识别精度。

关键词: 短时傅里叶变换; 双谱变换; 射频指纹; 密集连接; 非对称卷积

中图分类号: TN911.7

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2024208

DA-ResNeXt50 method for radio frequency fingerprint identification based on time-frequency and bispectral feature fusion

CHEN Mengdi¹, ZHANG Wei¹, SHEN Lei², LEI Fuqiang¹, ZHANG Jiafei²

1. School of Mechanical Engineering, Hangzhou Dianzi University, Hangzhou 310018, China

2. School of Communication Engineering, Hangzhou Dianzi University, Hangzhou 310018, China

Abstract: To address the problems that a single feature in radio frequency fingerprint recognition could not fully represent the integrity of the signal and that the differences between features of different classes were small, which limited the recognition accuracy, a DA-ResNeXt50 (ResNeXt50 with dense connection and ACBlock) method for radio frequency fingerprint identification based on time-frequency and bi-spectral feature fusion was proposed. Firstly, short-time Fourier transform (STFT) and bi-spectrum transform were performed separately on the signals collected

收稿日期: 2024-07-05; 修回日期: 2024-09-05

通信作者: 张巍, 42597@hdu.edu.cn

from different devices, the resulting images were bi-narized and then concatenated. By taking advantage of the advantages of both transformations in the time-frequency domain and high-order statistical characteristics respectively, the radio frequency fingerprint features of different devices can be extracted and characterized more comprehensively. Then, the DA-ResNeXt50 network model was proposed. Borrowing from the idea of dense connection, each layer of the four-layer residual unit was directly connected to all previous layers, promoting feature reuse and transmission, which enabled it to better capture subtle differences between classes. Finally, the asymmetric convolution block (AC-Block) was used to replace the 3×3 convolution in the last residual unit of the model. This effectively increased the receptive field of the network and enhanced the skeleton part of the convolutional kernel, thereby improving the performance of radio frequency fingerprint recognition. The experimental results show that compared with that of using a single feature extraction method, the proposed feature fusion approach significantly improves performance. Compared with various classical models, the improved model has higher recognition accuracy.

Key words: short-time Fourier transform, bi-spectrum transform, radio frequency fingerprint, dense connection, asymmetric convolution

0 引言

射频指纹识别是指通过信号处理手段,对采集的无线信号进行特征提取,从而实现辐射源设备个体识别的技术^[1]。近年来,随着无线通信技术的飞速发展,物联网应用正逐渐渗透到人们的生产生活之中,保障无线网络的安全也变得越来越重要。无线网络具有开放性等特点,网络通信容易受到窃听、欺骗等恶意攻击,这就导致了信息的泄露与破坏^[2]。射频指纹具有稳定性和唯一性等特点,能够有效地鉴别设备的身份,因此对提高无线网络安全具有重要意义。

传统的射频指纹识别方法主要是通过接收瞬态射频信号或稳态射频信号,在时域或变换域提取信号的物理参数特征及统计特征,选取较为单一的特征构成射频指纹,再利用分类器实现通信辐射源个体的识别^[3]。彭林宁等^[4]提出了一种使用星座轨迹图的射频指纹提取方法。在获取12种Zigbee设备信号的星座轨迹图的基础上,通过 K 均值聚类提取射频指纹特征并进行设备身份识别,信噪比(signal-to-noise ratio, SNR)高于10 dB时有90%以上的准确率。李雨珊等^[5]提出了基于射频发射信号提取小波系数,通过ReliefF算法和主成分分析(principal com-

ponent analysis, PCA)算法降维进行特征提取,并使用支持向量机(support vector machine, SVM)作为分类器进行分类识别,实验结果表明该算法在保证分类精度的情况下,有效地降低了数据维度和时间消耗。贾济铨等^[6]通过提取通信信号的围线积分双谱值作为设备个体识别的特征向量,使用SVM分类器进行识别。李超群等^[7]提出对无人机遥控器射频信号进行短时傅里叶变换提取射频信号的时频谱,通过分析时频谱获取能量瞬态特征,采用 K 近邻算法对提取的能量瞬态特征进行分类识别,在接收端信噪比为20 dB时识别率可达98.19%。

基于传统机器学习算法的射频指纹识别方法,存在依赖于复杂的特征提取、容易受信道影响、缺乏普适性等问题,这极大地限制了它们在实际场景中的应用,难以满足在复杂环境下高效、准确识别的需求。近年来,越来越多的研究将深度学习(deep learning, DL)引入射频指纹的特征提取与识别中,并取得了很好的效果。基于深度学习的设备识别方法通常利用分类神经网络直接处理原始信号或其变换形式,从而推断出设备的身份。这种方法省去了传统方法中复杂的特征工程步骤,大大地提高了设备识别的效率和准确性。Peng等^[8]将时域信号生成的差分星座轨



迹图送入卷积神经网络 (convolutional neural network, CNN) 中训练, 在 30 dB 的信噪比情况下识别准确率达到 99.1%。但在低信噪比环境中效果不佳, 噪声会导致差分星座轨迹图模糊, 影响 CNN 的特征提取和分类能力。叶文强等^[9]对雷达辐射源信号进行短时傅里叶变换 (short-time Fourier transform, STFT), 然后用 3 种不同的降维处理方法对 STFT 后得到的时频图进行特征提取并使用自编码器网络对雷达辐射源信号进行分类。但 STFT 对信号的非线性特性不敏感, 当面对具有显著非线性特性的雷达辐射源信号时, STFT 无法充分捕捉这些非线性特性, 会导致特征提取不完全, 从而降低射频指纹识别的准确率。谢跃雷等^[10]将采集到的 6 种同型号的路由器信号做双谱变换, 再使用改进的 12 层 ResNet 模型对双谱等高线图进行训练, 在实际电磁环境中识别准确率达 95.2%。但是路由器信号可能包含非平稳成分, 双谱变换的全局特性使得它不能有效捕捉到信号在特定时间和频率上的特征, 因此无法反映信号的局部时频特性, 容易导致信号中的关键信息丢失。

以上基于深度学习的射频指纹识别方法大部分都是基于 CNN 或残差网络 (residual neural network, ResNet)^[11]对单一信号特征进行特征提取, 从而完成射频指纹分类识别。它们使用的信号表示形式单一, 因此网络提取的特征也较为片面。此外, 传统的 CNN 每一层都是从前一层提取特征, 所以随着网络层数的增加通常会出现梯度消失、网络退化等问题。ResNet 采取跳跃连接的方法避免了深层神经网络带来的一系列问题。Xie 等^[12]提出了 ResNet 的增强版 ResNeXt, ResNeXt 可以在与 ResNet 保持相同复杂度的情况下, 获得更好的模型性能。但是 ResNeXt 在进行梯度反向传播时, 会径直经过快捷方式, 没有强制经过残差模块, 导致一些层可能无法得到充分利用; 而且由于整体模型的参数量比较大, 因此

在训练和推理阶段都需要强大的计算资源和内存。

基于上述分析, 本文提出了基于时频和双谱特征融合的 DA-ResNeXt50 射频指纹识别方法。首先将信号分别进行短时傅里叶变换和双谱变换, 之后将得到的图像二值化处理并拼接, 很好地解决了单一信号特征导致的信息量较少及无法全面表示设备细微特征等问题。然后构建了 DA-ResNeXt50 模型, 借鉴密集连接思想, 将四层残差单元每一层都与前面所有层直接相连, 还使用非对称卷积替换模型最后一层残差单元的 3×3 卷积, 使网络更好地捕捉到类间的细微差异, 提高射频指纹识别的性能。

1 基于特征融合的特征提取方法

1.1 短时傅里叶变换

STFT 是指信号在做傅里叶变换前加乘一个时间有限的窗函数, 并假定非平稳信号在分析窗的短间隔内是平稳的, 通过窗函数在时间轴上的移动, 在不同的时间点分析信号的频谱特性^[7]。窗函数的选择至关重要, 它决定了频谱分析的分辨率和时间定位的精度, 本文选用长度为 512 的汉明窗为窗函数。STFT 的优势在于可以同时表征信号在时域和频域的特征, 而且由于 STFT 通过使用窗函数, 将信号的分析局部化, 能够分析信号在局部时间范围内的频率特性, 这种特性使 STFT 能够反映射频信号在特定时间段内的频谱变化, 进而有助于提取射频指纹的局部特征。STFT 时频如图 1 所示。

设信号为 $x(t)$, 窗函数为 $h(t)$, 频率为 ω , 则信号的 STFT 定义如式 (1) 所示。

$$X(\omega, t) = \int_{-\infty}^{+\infty} x(\tau) h(\tau - t) e^{-j\omega\tau} d\tau \quad (1)$$

1.2 双谱变换

双谱又称为三阶谱, 定义为三阶累积量的二维傅里叶变换, 双谱能够反映出频谱值之间的两




图1 STFT时频

个频率成分的关系。对于非线性系统,在某些频率上具有很强的相关特性。双谱是最低阶、计算量最少、最简单,但是效率很高的高阶谱,因此是使用最广泛的方法^[13]。双谱提供了不同数据频率之间关系的补充数据,因此经常用来区分不同的设备内部状况。双谱等高线如图2所示,其中,等高线颜色深浅表示双谱幅值大小,幅值越大颜色越浅。双谱既关于原点对称,又关于 $y=\pm x$ 对称,本文使用间接法做双谱估计。




图2 双谱等高线

射频信号中通常包含非线性成分,这些非线性成分在双谱中会有较为明显的特征,通过双谱变换,可以检测出这些非线性特性。而且双谱对于提取发射机硬件在制造、老化等过程

中产生的细微差异较为敏感,这些差异体现在信号的高阶谱特征上,能够有效地区分不同的射频设备。

当序列 $x(t)$ 为零均值复平稳随机过程时,三阶累积量可以定义为:

$$c_{3x}(\tau_1, \tau_2) = \int_{-\infty}^{+\infty} x^*(t) x(t+\tau_1) x(t+\tau_2) dt \quad (2)$$

双谱变换可以表示为:

$$B(\omega_1, \omega_2) = \sum_{\tau_1=-\infty}^{+\infty} \sum_{\tau_2=-\infty}^{+\infty} c_{3x}(\tau_1, \tau_2) e^{-j(\omega_1 \tau_1 + \omega_2 \tau_2)} \quad (3)$$

其中, τ_1 与 τ_2 为相关函数的自变量,代表着两个时延; ω_1 与 ω_2 为双谱二维平面的轴;上标“*”表示复共轭。

1.3 特征融合

基于深度学习的方法,一般使用单一的特征图或特征矢量作为网络输入,提取的特征信息较片面,信息完整度有缺失。提高射频指纹识别的准确率,需要尽可能从各个方面及不同角度去提取有效特征,从而逼近真实的设备特征。因此本文提出了基于时频和双谱特征融合的射频指纹识别算法,将采集到的不同设备的信号分别进行短时傅里叶变换和双谱变换,再将得到的图像二值化处理并拼接,尺寸变换为 $224 \times 224 \times 1$ 。STFT主要关注的是信号在时频域上的局部特性,能够为射频指纹识别提供关于信号在不同时间和频率上的分布信息。双谱变换则能够捕捉信号的高阶统计特性,特别是由非线性系统产生的特性,而且对于提取发射机硬件在制造、老化等过程中产生的细微差异较为敏感。将这两种特征相结合,可以综合利用它们在时频域和高阶统计特性上的优势,更全面地提取和表征不同设备的射频指纹特征。二值化处理不仅可以突出拼接图像的时频特征和高阶谱特征中的重要信息,而且可以使特征和背景的区别更明显,增强图像的对比度,更有利于后续的网络特征提取,提高射频指纹识别的准确率。



图像二值化及拼接的具体过程如下。

首先, 将 STFT 时频图及双谱图进行灰度化处理, 按量化位数 8 进行量化, 将幅值映射到灰度图的像素值中, 映射范围为 [0, 255]。假设 $S(\omega, t)$ 表示时频谱, $S_{i,j}$ 表示第 i 行第 j 列元素的幅度值^[14], 则时频谱的量化计算式表示为:

$$X_{i,j} = \left\lfloor (2^8 - 1) \cdot \frac{S_{i,j}}{\max\{S_{i,j}\}} \right\rfloor \quad (4)$$

其中, $\lfloor \cdot \rfloor$ 表示向下取整; $S_{i,j}$ 表示对应的灰度图像第 (i, j) 个像素的数值。灰度图的尺寸为 875×656 , 则 $S_{i,j} \in [0, 255]$, $i \in [1, 875]$, $j \in [1, 656]$ 。

然后, 对得到的灰度图像进行二值化处理, 选用最大类间方差法。该方法通过遍历 [0, 255] 内所有可能的灰度值, 将图像划分为前景和背景两部分, 利用图像的灰度直方图, 计算每个灰度值作为阈值时前景和背景类间方差, 将最大类间方差对应的灰度值作为二值化阈值。使用该阈值将灰度值大于阈值的像素置为 1, 否则置为 0^[15], 类间方差的计算如式 (5) 所示。

$$\sigma^2 = \omega_0 \omega_1 (\mu_0 - \mu_1)^2 \quad (5)$$

其中, σ^2 表示类间方差; ω_0 和 ω_1 分别为前景和背景的像素比例; μ_0 和 μ_1 分别为前景和背景的灰度均值。

最后, 分别读取二值化后的时频图和双谱图 (尺寸均为 $875 \times 656 \times 1$), 通过在垂直方向上连接两个图像的像素数据, 实现简单的图像拼接, 得到尺寸为 $875 \times 1312 \times 1$ 的拼接图像。为适配后续的网络模型输入要求, 对拼接后的图像使用基于双线性插值方法的缩放操作, 将尺寸变换为 $224 \times 224 \times 1$ 。特征拼接图如图 3 所示, 图 3 (a) 为特征拼接的原图, 图 3 (b) 为特征拼接的二值化图。




图 3 特征拼接图

2 基于 DA-ResNeXt50 的射频指纹识别算法

本文以 ResNeXt50 模型为基础, 借鉴密集连接的思想, 将四层残差单元每一层都与前面所有层直接相连, 然后在最后一层残差单元结构中, 将原本的 3×3 卷积层替换成非对称卷积模块。DA-ResNeXt50 模型结构如图 4 所示。

DA-ResNeXt50 模型分类识别过程如下。首先, 输入经过二值化后的尺寸为 $224 \times 224 \times 1$ 的拼接图; 随后, 输入图像经过卷积核大小为 7×7 的卷积层, 再配合窗口大小为 3×3 的最大池化层改变图像通道和大小; 接着, 将 4 组 ResNeXt 残差单元的每一层都与前面所有层直接相连, 再将 Conv4 的 3×3 卷积替换为非对称卷积的 3×3 、 1×3 以及 3×1 这 3 个卷积, 以便从不同的空间提取多尺度的射频指纹特征再进行线性相加融合, 实现强化射频指纹特征提取的目的。其中 ResNeXt 残差模块的设计融合了 ResNet、Inception 架构以及组卷积的概念, 将高维卷积分解为 32 个相同的低维卷积进行融合输出, 这有利于网络学习不同的射频指纹特征; 最后, 将提取的射频指纹特征输入平均池化层、全连接层和 softmax 层以完成分类识别任务。

2.1 密集连接

DenseNet^[15]的主要特点是在输入和输出层之间引入更多的短连接, 从而提高网络的效率和精度。在传统卷积神经网络中, 每一层仅与相邻的层相连, 而在密集卷积神经网络中, 每一层都与前面所有层直接相连, 这种直接连接的方式可以




图4 DA-ResNeXt50 模型结构

较大程度地减少信息损失，使得网络能够更深入、更准确地学习到射频指纹特征。密集连接的具体方法是先改变上层输出的通道数和特征尺寸，然

后对下层特征进行融合匹配，最后输出到后续的卷积层。密集连接结构如图5所示，先将第一层输出 L_1 使用快捷连接connect1改变形状，使其满



足第3层的输入，再与第2层输出 L_2 融合后输入第3层，经过Conv3作用后输出 L_3 ；然后将第1层输出 L_1 、第2层输出 L_2 分别使用快捷连接connect2和connect3改变形状，使其满足第4层的输入，再与第3层输出 L_3 融合后输入第4层，经过Conv4作用后输出 L_4 ^[16]。具体计算过程如下。




图5 密集连接结构

$$L_2 = \text{Conv2}(L_1) \quad (6)$$

$$\text{out}_1 = \text{connect1}(L_1) \quad (7)$$

$$L_3 = \text{Conv3}(L_2 + \text{out}_1) \quad (8)$$

$$\text{out}_2 = \text{connect2}(L_1) \quad (9)$$

$$\text{out}_3 = \text{connect3}(L_2) \quad (10)$$

$$L_4 = \text{Conv4}(L_3 + \text{out}_2 + \text{out}_3) \quad (11)$$

其中， L_2 、 L_3 和 L_4 为网络模型残差层Conv2、Conv3和Conv4的输出； out_1 、 out_2 和 out_3 为快捷连接connect1、connect2和connect3的输出。

2.2 非对称卷积

在卷积运算的过程中，位于中心交叉部分的横向和纵向卷积核所捕获的特征更为重要。ACBlock^[17]充分利用了这一特点，在一般 3×3 卷积的基础上并行了 1×3 和 3×1 两个矩形卷积核的卷积，然后将这3个卷积层的计算结果进行融合获得卷积层的输出，非对称卷积模块如图6所示。ACBlock在卷积过程中权重分布不均，在卷积核交叉部分的骨架结构上具有更高的权重，形成非对称的结构，因此可以捕获更多有效的射频指纹特征。而且通过减少参数量，ACBlock减少了学习冗余射频指纹特征的可能性，可以有效地提高模型的计算效率。ACBlock卷积模块中的3个并行卷积核共享

同一个滑动窗口，通过式(12)进行转换。




图6 非对称卷积模块

$$I * J^{(1)} + I * J^{(2)} = I * (J^{(1)} \oplus J^{(2)}) \quad (12)$$

其中， I 表示矩阵， $J^{(1)}$ 和 $J^{(2)}$ 是具有兼容尺寸的两个2D核， $\oplus$ 表示在对应位置下的求和操作。

DA-ResNeXt50主要针对原网络模型的最后一组残差单元的 3×3 卷积进行，将其替换为ACBlock卷积块，对拼接图分别进行卷积，然后再将整个分组卷积融合，与短接的分支相加，经过激活函数进行激活输出到下一层^[18]。具体计算过程如下。

$$X_{3 \times 3} = \text{Conv}_{3 \times 3}(X) \quad (13)$$

$$X_{1 \times 3} = \text{Conv}_{1 \times 3}(X) \quad (14)$$

$$X_{3 \times 1} = \text{Conv}_{3 \times 1}(X) \quad (15)$$

$$Y = \text{BN}(X_{3 \times 3} + X_{1 \times 3} + X_{3 \times 1}) \quad (16)$$

$$X = \text{ReLU}(Y) \quad (17)$$

其中， X 为输入矩阵， $\text{Conv}_{n \times n}$ 表示卷积核尺寸为 $n \times n$ 的卷积， Y 为3个不同大小卷积核卷积后进行融合的结果，BN为正则化操作，ReLU为非线性运算。

3 实验结果与分析

3.1 数据集与实验环境

实验所用服务器GPU为NVIDIA GEFORCE RTX 3090，Ubuntu版本为22.04.4，深度学习框架为Pytorch，采用Adam作为训练的优化器，初始学习率为0.000 1，使用交叉熵函数作为损失函数，Batch_size设置为32，训练轮次为70次。

实验采用的数据集是由4台同型号的发射机在真实场景下距离接收机约200 m处发出的不同信号，信号采用正交相移键控(quadrature phase

shift keying, QPSK) 调制方式, 采样频率为 96 kHz, 载波频率为 24 kHz, 信噪比范围为 $\{-5 \text{ dB}, 0, 5 \text{ dB}, 10 \text{ dB}, 15 \text{ dB}, 20 \text{ dB}, 25 \text{ dB}\}$, 信号采集接收的硬件设备如图 7 所示。将信号序列分割为每段 1 024 个采样点的 600 段, 共 2 400 段, 将图像经过二值化处理后制成数据集。再按 8:1:1 的比例进行划分, 其中 1 920 张图像作为训练集, 240 张图像作为验证集, 240 张图像作为测试集。

本文信号预处理及特征提取过程均在 MATLAB 2021a 仿真平台上进行, STFT 窗函数采用汉明窗, 窗口长度为 512, 重叠长度为 256, FFT 长度为 1 024; 双谱变换采用间接估计法, 滞



(a) 信号发射机设备

(b) 信号接收机设备

图 7 信号采集接收的硬件设备

后数为 49, 每段样本数为 64, 重叠百分比为 50, 无偏移, FFT 长度为 128, 窗口选用 Parzen 窗。

3.2 特征图可视化分析

在信噪比为 20 dB 的环境下, 对本文提出的 DA-ResNeXt50 进行特征图的可视化, 以便直观地描绘射频指纹特征。将该可视化结果与原始 ResNeXt50 和 ResNet50 进行对比, 特征图可视化对比如图 8 所示。热力图中的深色区域是模型学




图 8 特征图可视化对比



习到的设备特征, 即模型在分类识别时重点关注的区域。

图8中, 图8(a)为二值化拼接图, 图8(b)、图8(c)和图8(d)分别为二值化拼接图在ResNet50、ResNeXt50以及DA-ResNeXt50下的热力图。从图8(b)、图8(c)和图8(d)中矩形框区域可以明显看出设备特征在不同模型下的效果。在ResNet50中只关注到部分时频特征, 还存在关注区域错误等问题。在ResNeXt50中, 模型关注区域扩大, 但是关注点还是集中在双谱特征上, 几乎没有关注到时频特征。在本文提出的DA-ResNext50中, 有效地增大了关注区域, 从图8(d)中可以看出模型关注区域在时频特征和双谱特征两方面, 减少了关注点偏移及错误等问题, 能够准确地关注到设备的特征信息。

3.3 特征提取对比实验结果与分析

为评估所提算法的性能, 分别采用本文提出的二值化拼接图+DA-ResNeXt50方法与原拼接图+DA-ResNeXt50方法、STFT时频图+DA-ResNeXt50方法、双谱图+DA-ResNeXt50方法以及HHT时频谱图+DA-ResNeXt50方法进行仿真实验, 测试所提方法是否可以保证射频指纹识别的精度。

不同信噪比下各特征提取方法对比如图9所示, 从图9可以看出, 在同一训练集和测试集下, SNR为-5 dB到25 dB时, 本文所提方法的准确率均高于其他5种对比方法。在SNR为10 dB时, 所提的方法比原拼接图+DA-ResNeXt50方法、STFT时频图+DA-ResNeXt50方法、双谱图+DA-ResNeXt50方法以及HHT时频谱图+DA-ResNeXt50方法分别高出了5.42%、8.75%、20.84%和45.00%。经过对比实验, 验证了所提方法的有效性, 能够准确地关注到目标图像中的重要特征。




图9 不同信噪比下各特征提取方法对比

3.4 模型对比实验结果及分析

将本文所提方法与原始ResNeXt50^[12]、ResNet50^[11]、GooleNet^[20]以及Vgg16^[21]等主流深度学习网络进行性能对比, 统计4种不同设备下各模型的平均识别率。

不同信噪比下各模型对比如图10所示, 本文所提的DA-ResNeXt50相较于其他网络表现出较强的分类识别性能。当SNR为0 dB时, 本文所提的DA-ResNeXt50的准确率相比原始ResNeXt50、ResNet50、GooleNet和Vgg16分别提升了5.42%、10.00%、15.00%和17.50%, 本文所提方法具有较为明显的分类识别效果。




图10 不同信噪比下各模型对比

3.5 消融实验

为了验证所提方法的可行性,同时确定改进结构在性能改善中所起的作用,在信号不加噪的情况下进行消融实验,消融实验结果见表1。

表1 消融实验结果

ResNeXt50	密集连接	ACBlock	准确率
√	—	—	96.67%
√	√	—	97.92%
√	—	√	98.33%
√	√	√	98.33% (原拼接图)
√	√	√	99.17% (二值化拼接图)

表1展示了实验中改进的各个模块对实验结果的影响,第1行实验数据为二值化处理后的数据集在原ResNeXt50下的识别准确率,在ResNeXt50的残差结构中单独引入密集连接和ACBlock的准确率,分别提升了0.84%和1.69%。表1中第4行和第5行实验数据分别为原拼接图数据集、二值化拼接图数据集在两种改进点共同融入的情况下得到的准确率,较原模型相比分别提升了1.69%和2.09%,但原拼接图数据集没有经过二值化处理后的拼接图数据集准确率高,由此说明本文所提方法有效。

3.6 不同特征提取方法及模型推理时间对比分析

为评估不同特征提取方法及网络模型识别的效率,进行对比实验。由于推理时间可以从侧面反映模型的复杂程度,因此在同一DA-ResNeXt50模型下对比不同特征提取方法的推理时间以及在同一二值化拼接图的特征提取方法下对比不同网络模型的推理时间,不同特征提取方法推理时间对比见表2,不同模型推理时间对比见表3。

由表2可以看出,在同一DA-ResNeXt50模型下,二值化拼接图的推理时间与原拼接图、STFT时频图及双谱图相似,说明在进入网络之前进行图像拼接并不会导致网络模型复杂度增加。与原拼接图相比,二值化拼接图的推理时间

减少了约0.564 ms,这表明二值化处理减少了一定的计算量。单独使用STFT时频图与单独使用双谱图的推理时间较使用HHT时频谱图少,说明STFT时频图和双谱图在计算效率上相对于HHT时频谱图具有一定的优势。由表3可以看出,本文所提的DA-ResNeXt50模型的推理时间略高于ResNeXt50、ResNet50和Vgg16,这表明DA-ResNeXt50模型复杂度相较原模型有所增加,但通过识别准确率可以看出其识别效果得到了较大提升,因此具有一定的性能优势。

表2 不同特征提取方法推理时间对比

特征提取方法	推理时间/ms
二值化拼接图	12.402
原拼接图	12.966
STFT时频图 ^[19]	12.336
双谱图 ^[13]	12.228
HHT时频谱图 ^[14]	14.027

表3 不同模型推理时间对比

网络模型	推理时间/ms
ResNeXt50 ^[12]	11.028
ResNet50 ^[11]	11.025
GoogleNet ^[20]	15.800
Vgg16 ^[21]	11.150
DA-ResNeXt50	12.402

4 结束语

本文提出了一种基于时频和双谱特征融合的DA-ResNeXt50射频指纹识别方法。通过将采集到的不同设备的信号分别进行短时傅里叶变换和双谱变换,再对得到的图像进行二值化处理并拼接,解决了单一特征无法全面表示信号的完整性的问题;DA-ResNeXt50构建时在原始网络中借鉴密集连接思想,将浅层射频指纹特征和深层射频指纹特征相结合,促进了特征的复用和传递,解决了类间特征差异较小从而限制识别准确率等问题;同时将模型最后一组残差单元的3×3卷积



核替换为非对称卷积模块,有效地增加了网络的感受野,增强了卷积核的骨架部分,提高了射频指纹识别的性能。实验结果表明,本文提出的方法具有较高的识别准确率和可靠性。

参考文献:

- [1] 张振,贾济铖,康健,等. 射频指纹识别技术方法综述[J]. 无线电通信技术, 2021, 47(3): 249-258.
ZHANG Z, JIA J C, KANG J, et al. Overview of RF Fingerprint identification technology methods[J]. Radio Communications Technology, 2021, 47(3): 249-258.
- [2] 张晔. 基于深度学习的射频指纹识别系统设计与实现[D]. 北京: 中国科学院大学(中国科学院国家空间科学中心), 2021.
ZHANG Y. Design and implementation of RF fingerprint identification system based on deep learning[D]. Beijing: National Space Science Center, Chinese Academy of Sciences, 2021.
- [3] 邓涵方. 基于深度学习的射频指纹识别技术研究[D]. 桂林: 桂林电子科技大学, 2022.
DENG H F. Research on RF fingerprint identification technology based on deep learning[D]. Guilin: Guilin University of Electronic Technology, 2022.
- [4] 彭林宁, 胡爱群, 朱长明, 等. 基于星座轨迹图的射频指纹提取方法[J]. 信息安全学报, 2016, 1(1): 50-58.
PENG L N, HU A Q, ZHU C M, et al. Radio fingerprint extraction based on constellation trace figure[J]. Journal of Cyber Security, 2016, 1(1): 50-58.
- [5] 李雨珊, 谢非佚, 陈松林, 等. 适合终端的射频指纹信号特征提取及识别[J]. 通信技术, 2018, 51(1): 63-66.
LI Y S, XIE F Y, CHEN S L, et al. Feature extraction and recognition of radio frequency fingerprint signal suitable for terminal [J]. Communications Technology, 2018, 51(1): 63-66.
- [6] 贾济铖, 齐琳. 基于双谱的射频指纹提取方法[J]. 太赫兹科学与电子信息学报, 2021, 19(1): 107-111.
JIA J C, QI L. RF fingerprint extraction method based on bispectrum[J]. Journal of Terahertz Science and Electronic Information Technology, 2021, 19(1): 107-111.
- [7] 李超群, 王小明. 基于短时傅里叶变换的无人机射频指纹分类识别[J]. 通信技术, 2022, 55(9): 1202-1207.
LI C Q, WANG J M. Classification and identification of UAV RF fingerprints based on short-time Fourier transform[J]. Communications Technology, 2022, 55(9): 1202-1207.
- [8] PENG L N, ZHANG J Q, LIU M, et al. Deep learning based RF fingerprint identification using differential constellation trace figure[J]. IEEE Transactions on Vehicular Technology, 2020, 69(1): 1091-1095.
- [9] 叶文强, 俞志富. 基于联合时频辐射源信号识别方法[J]. 电子信息对抗技术, 2018, 33(5): 16-19, 50.
YE W Q, YU Z F. Signal recognition method based on joint time-frequency radiant source[J]. Electronic Information Warfare Technology, 2018, 33(5): 16-19, 50.
- [10] 谢跃雷, 邓涵方. 基于改进 ResNet 的射频指纹识别方法[J]. 电讯技术, 2022, 62(4): 416-423.
XIE Y L, DENG H F. A radio frequency fingerprinting identification method based on improved ResNet[J]. Telecommunication Engineering, 2022, 62(4): 416-423.
- [11] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]// Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). Piscataway: IEEE Press, 2016: 770-778.
- [12] XIE S N, GIRSHICK R, DOLLAR P, et al. Aggregated residual transformations for deep neural networks[C]// Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2017: 5987-5995.
- [13] 马爽. 基于多特征融合的无线通信设备指纹特征提取及识别[D]. 成都: 电子科技大学, 2020.
MA S. Fingerprint feature extraction and identification of wireless communication equipment based on multi-feature fusion[D]. Chengdu: University of Electronic Science and Technology of China, 2020.
- [14] 王小颖. 电子侦察中的调制识别和身份识别[D]. 成都: 电子科技大学, 2022.
WANG X Y. Modulation recognition and identity recognition in electronic reconnaissance[D]. Chengdu: University of Electronic Science and Technology of China, 2022.
- [15] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks[C]// Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2017: 2261-2269.
- [16] LI X Y, GUO L, YANG J D, et al. Research on classification of wild mushroom based on feature fusion and attention mechanism[C]// Proceedings of the 2023 IEEE 6th Information Technology, Networking, Electronic and Automation Control Conference (ITNEC). Piscataway: IEEE Press, 2023: 114-119.
- [17] DING X H, GUO Y C, DING G G, et al. ACNet: strengthening the kernel skeletons for powerful CNN via asymmetric convolution blocks[C]// Proceedings of the 2019 IEEE/CVF In-

ternational Conference on Computer Vision (ICCV). Piscataway: IEEE Press, 2019: 1911-1920.

- [18] 张洁, 穆静, 钱智哲. 改进的 ResNeXt50 神经网络面部表情识别方法[J]. 西安工业大学学报, 2022, 42(6): 610-619.

ZHANG J, MU J, QIAN Z Z. Facial expression recognition method based on improved ResNeXt50 neural network[J]. Journal of Xi'an Technological University, 2022, 42(6): 610-619.

- [19] 杜贵琪. 基于人工智能的射频指纹识别技术研究[D]. 成都: 电子科技大学, 2022.

DU G Q. Research on RF fingerprint identification technology based on artificial intelligence[D]. Chengdu: University of Electronic Science and Technology of China, 2022.

- [20] SZEGEDY C, LIU W, JIA Y Q, et al. Going deeper with convolutions[C]//Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2015: 1-9.

- [21] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. arXiv e-Prints, 2014: arXiv: 1409.1556.

[作者简介]



陈梦迪 (1998-), 女, 杭州电子科技大学机械工程学院硕士生, 主要研究方向为信号处理。



张巍 (1985-), 男, 杭州电子科技大学机械工程学院特聘副研究员, 主要研究方向为信号分析与处理。



沈雷 (1979-), 男, 博士, 杭州电子科技大学通信工程学院教授、博士生导师, 主要研究方向为数字图像处理、模式识别。



雷富强 (1981-), 男, 杭州电子科技大学机械工程学院特聘研究员、博士生导师, 主要研究方向为智能装备与智能系统。



张佳飞 (1998-), 男, 杭州电子科技大学通信工程学院硕士生, 主要研究方向为信号处理。