

DOI:10.20079/j.issn.1001-893x.240806002

基于射频指纹多分辨率特征融合的辐射源个体识别方法*

余江^{1a}, 陈川^{1a}, 贾勇^{1a}, 姚光乐^{1b}, 王琛^{1b}, 张喜娟², 陈亚锋³

(1. 成都理工大学 a. 机电工程学院; b. 计算机与网络安全学院, 成都 610059;
2. 成都飞机工业(集团)有限责任公司, 成都 610073; 3. 四川酷比通信设备有限公司, 成都 644000)

摘要:针对辐射源分类任务存在的特征信息表达有限和分类精度低等问题,提出了一种基于多分辨率特征融合的辐射源个体识别方法。该方法利用短时傅里叶变换 3 种不同分辨率的时频域谱图表达辐射源个体特征。使用 ResNext50 构建多通道卷积神经网络,提取不同时频分辨率的特征。在网络中引入多通道特征加权融合机制,对不同通道的特征进行加权融合,组合不同分辨率下的特征信息。实验证明,这种方法提升了辐射源信号的细微指纹信息表达能力,相比特征层融合方法和单一特征表达方法两种方法,识别准确率分别提升 2.15% 和 6.8%。

关键词:辐射源个体识别;射频指纹;多分辨率特征融合;短时傅里叶变换

开放科学(资源服务)标识码(OSID):



微信扫描二维码
听独家语音释文
与作者在线交流
享本刊专属服务

中图分类号:TN911.7 文献标志码:A 文章编号:1001-893X(2025)11-1844-07

Individual Radiation Source Recognition Based on Multi-resolution Fusion of Radio Frequency Fingerprints

YU Jiang^{1a}, CHEN Chuan^{1a}, JIA Yong^{1a}, YAO Guangle^{1b}, WANG Chen^{1b},

ZHANG Xijuan², CHENG Yafeng³

(1a. School of Mechanical and Electrical Engineering; 1b. School of Computer and Cyber Security, Chengdu University of Technology, Chengdu 610059, China; 2. Chengdu Aircraft Industrial (Group) Co., Ltd, Chengdu 610073, China;
3. Sichuan Koobee Communication Company Limited, Chengdu 644000, China)

Abstract: For the problems of limited expression of characteristic information and low classification accuracy in radiation source classification tasks, an individual radiation source recognition method based on multi-resolution feature fusion is proposed. In this method, the individual characteristics of the radiation source are expressed by using three time-frequency spectra with different resolutions obtained through the Short-Time Fourier Transform. Multi-channel convolutional neural networks are constructed using ResNext50 to extract features with different time-frequency resolutions. A multi-channel feature weighted fusion mechanism is introduced into the network, and the features of different channels are fused by feature weighted fusion, combining the feature information from different resolutions. Experiments show that this method improves the ability to express the subtle fingerprint information of the radiation source signal, and compared with that of the feature layer fusion method and the single feature expression method, the recognition accuracy is improved by 2.15% and 6.8%, respectively.

Key words: individual radiation source recognition; RF fingerprint; multi-resolution feature fusion; short-time Fourier transform

* 收稿日期:2024-08-06;修回日期:2024-10-20

基金项目:国家自然科学基金资助项目(U20B2070);四川省重点研发项目(2022YFS0531);成都市“揭榜挂帅”科技项目(2023-JB00-00023-GX)

通信作者:陈川 Email:17103738@qq.com

0 引言

随着新一代通信技术快速发展,无线通信设备数量不断增长,对于通信设备的识别和认证成为信息安全管理不可或缺的一部分。在信息安全方面,射频指纹识别方法被广泛采用在物理层设备识别、入侵检测、访问管控、克隆验证以及安全定位等多个领域。该方法通过表达和提取通信设备中细微且可区分的固有特征来区分不同的通信设备。

自射频指纹识别技术被提出以来,主要分为两个研究方向,分别为基于信号处理的特征表达方向和基于深度学习的特征提取方向。特征表达^[1]包括表达不同变换域的特征以及不同变换域特征融合的表达方法^[2-7]。多数时频特征提取方法都是建立在稳态信号之上,但是在瞬态信号中也包含着信号特征。

在辐射源识别问题中的特征表达方面,多为单一特征表达方式,输入特征单一,无法全面捕捉信号的多维信息,在复杂环境下可能会导致在复杂环境中识别能力受限。

深度特征提取方法在信号处理的基础上使用深度学习框架进一步提取特征和识别分类^[8-13]。

但是,现有方法多依赖单一特征进行分类,导致识别能力和准确性受限。单一特征忽略了信号中的多维信息,难以在复杂或噪声环境下保持鲁棒性,尤其在信号种类繁多、干扰复杂时,难以提供充分的判别依据。因此,结合多种特征进行融合,有助于提高分类精度,并增强系统的适应性与鲁棒性。

本文提出一种多分辨率融合方法,将同一特征方法下表达出的不同时频分辨率谱图作为神经网络输入,通过多通道特征加权融合机制融合不同分辨率特征,作为分类识别的依据。

1 多分辨率特征融合的个体识别方法

基于神经网络的辐射源个体识别任务可以分为信号预处理、特征表达、特征提取、特征融合、分类识别等环节,流程如图 1 所示。

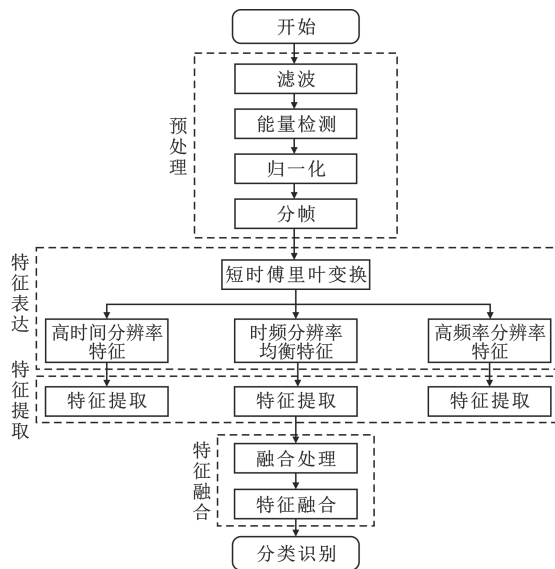


图 1 基于神经网络的辐射源个体识别流程

多分辨率特征融合过程如下:首先,将侦收到的信号在信号预处理中做不同窗口长度的短时傅里叶变换,得到高时间分辨率、时频率分辨率均衡、高频率分辨率 3 种不同时频分辨率的时频谱图;其次,将 3 种时频谱图分别作为 3 个 ResNext50 网络的输入,在网络分类器之前,通过特征加权融合;最后,将融合的特征作为输出层,输入到分类器中进行分类。

这种多分辨率的表达方式放大信号在时间和频率上的细微特征,再通过神经网络强大的数据分析能力捕捉不同分辨率下的主要特征,提升特征的表达范围。不同分辨率特征存在差异,但都为同一信号的不同描述尺度,它们之间具有内在的关联性。通过特征融合,这种方法有效拼接了不同分辨率的特征信息。

1.1 信号预处理

由于接收的原始信号无法直接表征信号特征,所以需进行一系列信号预处理操作。对侦收到的原始射频信号进行滤波降噪、能量检测、信号分帧、时频分析等一系列处理。具体地,首先通过小波去噪去除信号中包含的噪声干扰和杂波干扰,避免杂波项对后续处理造成干扰;其次,原始信号中有效信号之间夹杂着多段无效噪声信号,为剔除无效信号,使用能量检测方法检测有效信号的起始时刻和结束时刻,实现有效信号的提取;随后,对提取的信号做统一长度的分帧处理,为后续时频分析提供一致长度信号,避免了不同长度下有效信号的计算量和时频

分辨率不同等问题;最后,为获得更加合适的表达方式,在对统一时间长度的一维时域分帧信号进行变换,将一维时域信号转换为二维时频谱图送入网络。

连续小波变换 (Continuous Wavelet Transform, CWT) 通过多尺度分析捕捉信号细节,但数据冗余高,计算量大;离散小波变换 (Discrete Wavelet Transform, DWT) 高效但下采样会导致信息丢失;CWD 改进了魏格纳-维尔分布 (Wigner-Ville Distribution, WVD) 中的交叉干扰,适合复杂信号,但计算复杂度较高;WVD 有高分辨率但交叉项干扰严重。相比之下,短时傅里叶变换 (Short-Time Fourier Transform, STFT) 计算简单且效率高,通过调整窗口长度可平衡时间和频率分辨率,结合多尺度窗口融合可进一步优化,解决时间-频率分辨率之间的折衷问题,因此选择 STFT 更为合理。

STFT 是一种在信号处理中常用的线性时频分析方法,其基本原理是将非平稳信号视为一系列短时间内的平稳信号的叠加。其核心思想是通过局部平稳化,将信号在时间和频率上分解为多个小块,在每个小块上进行傅里叶变换以获得频率信息。

STFT 的定义为

$$\text{STFT}_s(t, f) = \sum_{n=-\infty}^{+\infty} s(n) h(n-t) e^{-j2\pi n f} \quad (1)$$

式中: $s(n)$ 为输入信号; $h(n)$ 为窗函数; $\text{STFT}_s(t, f)$ 中 t 为窗函数在时间轴滑动的位置, f 为频率。短时傅里叶变换的实现方式是通过使用窗函数 $h(n)$ 对信号进行分段,并在每个窗口内进行傅里叶变换。

短时傅里叶变换是一种在时间上分段分析信号频谱的时频方法。在 STFT 中,窗函数起着至关重要的作用,它定义每个时间段中信号被分析的时域特性,常见窗口包括矩形窗、汉宁窗、高斯窗等。由于汉宁窗在时域和频域都具有较好的性质,它的主瓣衰减较快,有较小的旁瓣,并且频谱泄露较小,所以使用汉宁窗作为短时傅里叶变换的窗函数。汉宁窗函数表达式为

$$h(n) = 0.5 - 0.5 \cos\left(\frac{2\pi n}{N-1}\right) \quad (2)$$

式中: n 为样本点索引, $n=0, 1, 2, 3, \dots, N-1, N$ 表示窗函数的总长度。

通过快速傅里叶变换可以观察到,8 种不同电台之间的频率分布大致相同,但是不同电台之间具

有细微的频率分布差异,如图 2 所示。




图 2 频率分布对比

而在短时傅里叶变换中,窗口长度是一个重要的参数,它决定了二维时频谱图的时间和频率的分辨率。较长的窗口长度可以提供更多的频率成分,但时间分辨率会降低;较短的窗口长度则具有更多的时间信息,但是会丢失信号低频信息。因此,不同窗口长度的 STFT 谱图会呈现出不同的时频特征细节,可以更好地区分不同电台之间的特征差异。

考虑到时频特征之间关联性以及分帧信号长度,选取窗口长度 64、128、256 作为不同分辨率下短时傅里叶变换的窗口长度。通过谱图可以观察信号在时间轴和频率轴上的变化,不同长度窗口下特征谱图具有明显差异。如图 3 所示,高时间分辨率的窗口长度为 64,较短的窗口长度会拥有更好的时间分辨率。如图 4 所示,时频分辨率均衡的窗口长度为 128 点,可以平衡谱图中时间和频率信息。如图 5 所示,高频率分辨率采用长度为 256 的窗长,对于较长的窗口长度会导致频率分辨率更高,包含信号更多的频率成分。可以通过不同的描述尺度放大信号细微特征。




图 3 窗口长度为 64 的时频谱




图 4 窗口长度为 128 的时频分辨率谱




图 5 窗口长度为 256 的时频分辨率谱

杂的特征,在 ResNet18 的基础上提出了 ResNet34、ResNet50 等层数更深的模型。

为了得到更好的辐射源分类结果,本文采用 ResNext-50 网络结构^[15]。ResNext50 具有与 ResNet-50 相同的 50 层卷积层,但是 ResNext 网络在残差结构中引入 Inception 中多支路思想,称为分组卷积。图 6 所示为 ResNext 的 Block 结构,图中每个方框都代表一层网络卷积层结构,方框中 3 个数数据分别代表输入数据的通道个数、卷积核尺寸和输出通道个数。

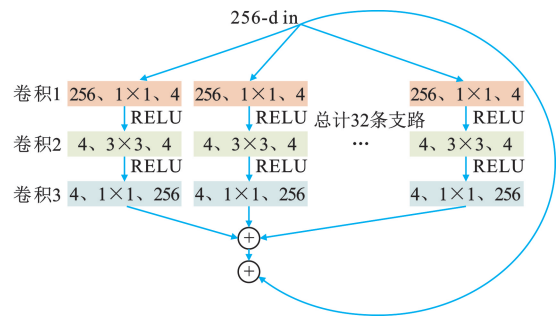


图 6 ResNext 的 Block 结构

1.2 ResNext50 网络

ResNet 网络结构^[14]是由微软研究院提出的一种深度残差网络,旨在解决深度神经网络训练时出现的梯度消失和梯度爆炸问题。随后为了提取更复

网络结构图如图 7 所示,分别通过 3 个 ResNext50 网络提取不同特征分辨率下的特征,通过加权融合将不同特征融合,输入下一层网络结构,最后输入到全连接层。




图 7 特征融合网络结构

1.3 特征融合

由于不同分辨率特征输入下网络提取特征不同,为学习多个分辨率特征,提高网络分类识别能力,使用特征加权融合方法,通过权重调整输出特征向量。多通道特征加权融合流程如下:

第一步,输入多通道特征数据集 T_K 。

$$T_K = [T_{k,1}, T_{k,2}, \dots, T_{k,n}] \quad (3)$$

式中: $(T)_K$ 为第 k 个通道的数据集, $K=1,2,3; j=1,2, \dots, n$ 为通道样本数。

第二步,计算通道信息熵,定义为

$$S_K = -\frac{1}{\ln n} \sum_{j=1}^n (T_{k,j}) \ln(T_{k,j}) \quad (4)$$

式中: S_K 为第 k 个通道的信息熵; $T_{k,j}$ 为第 k 个通道的第 j 个特征。

第三步,各通道的融合权重为

$$\alpha_k = \frac{1-S_K}{n - \sum_{j=1}^n S_K} \quad (5)$$

式中: α_k 为第 k 个通道的融合权重, $0 \leq \alpha_k \leq 1$ 。

$$\alpha_1 + \alpha_2 + \alpha_3 = 1 \quad (6)$$

第四步,计算加权多分辨率特征融合后的数据。

$$A = \frac{\alpha_1}{\sum_{l=1}^k \alpha_K} T_1 + \frac{\alpha_2}{\sum_{l=1}^k \alpha_K} T_2 + \frac{\alpha_3}{\sum_{l=1}^k \alpha_K} T_3 \quad (7)$$

式中: A 为 K 类电台加权多通道特征融合后的特征矩阵。

2 实验与分析

2.1 实验数据

本文实验环境使用 Windows10 系统,采用 MATLAB R2020a 平台处理数据集,使用 Pytorch 框架构建网络,网络实验在显存为 16 GB 的 NVIDIA GeForce RTX 4080 GPU 上完成。神经网络选用 ResNext50,学习率设置为 0.000 1,批量大小(Batch Size)设置为 32。训练集与测试集的比例为 8:2。

实验数据采集自 8 类电台,使用编号为 210~217 的 8 部同型号电台辐射源设备数据完成实验。每类电台原始数据以单通道采集,采样频率为

200 MHz,每类电台原始数据存储保存为 80 GB 大小的数据包。8 类电台共 8 个数据包,每个数据包中包含多段有效信号,通过预处理将有效信号提取并表征。

2.2 实验结果与分析

在特征融合网络中,每一种分辨率各 1 000 个样本,每类电台特征样本个数总计 3 000 个。


实验中分别对比高时间分辨率、时频分辨率均衡以及高频率分辨率,分别称为对比实验 1、对比实验 2、对比实验 3。在对比实验中对特征融合网络均输入同一种特征分辨率,样本总数 3 000 个。

将 3 种不同时频分辨率方法与 3 种时频分辨率特征融合的方法,使用 ResNext50 特征融合网络作为识别网络。


通过混淆矩阵可视化进行对比。3 种时频分辨率识别结果与 3 种时频分辨率特征融合的识别结果如图 8 所示,其中,图 8(a)为高时间分辨率的混淆矩阵,识别准确率为 95.42%;图 8(b)为时间频率分辨率均衡的混淆矩阵,识别准确率为 94.21%;图 8(c)为高频率分辨率的混淆矩阵,识别准确率为 93.69%;图 8(d)为经过 3 种时频分辨率特征融合方法的混淆矩阵,识别准确率为 99.21%,相较于单一分辨率识别精度提升 3.79%。

将 3 种不同时频分辨率的时频谱图送入特征融合的网络,将 4 种方法在测试集的准确率曲线进行对比。如图 9 所示,从最大准确率的角度分析,识别效果为特征融合>高时间分辨率>时频均衡分辨率>高频率分辨率。


使用传统方法中的 ResNet34 网络作为对比网络,通过网络测试集准确率曲线对比,每类样本数量 3 000 个,其中特征融合准确率为 99.21%,特征融合识别准确率为 94.21%,特征单类识别准确率为 92.41%。多分辨率特征融合识别效果优于单一分辨率融合,单一分辨率融合效果优于单一分辨率特征识别。如图 10 所示,识别效果为特征融合>单类特征融合识别>单类特征识别。




(a) 高时间分辨率



(b) 时间频率分辨率均衡



(c) 高频率分辨率



(d) 特征融合

图 8 混淆矩阵




图 9 测试集准确率曲线




图 10 测试集准确率曲线

文献[16]中的特征层融合方法采用特征拼接的方法,拼接3种不同的时频特征图,达到特征融合的目的。该方法与本文3种高维特征融合进行了对比,使用3种分辨率特征各1000个样本即每类电台1000个特征层融合样本,在输入网络前融合。对比结果如图11所示,对比方法最高准确率为97.09%。由于对比方法中使用单个网络提取特征,网络收敛速度明显高于本文,但本文方法准确率高与特征层融合方法。




图 11 不同方法准确率对比曲线

3 结束语

本文提出了一种基于多分辨融合的辐射源个体识别方法,将侦收的电台射频信号通过不同窗长的 STFT 得到高时间分辨率、高频率分辨率、均衡时频分辨率 3 种不同时频分辨率的时频谱图,增强网络输入特征。在特征提取网络中,通过多通道特征加权将 3 种特征融合,从而提高特征分类识别能力。

实验结果证明,本文采用基于多分辨融合的辐射源个体识别方法用于完成辐射源识别任务能够达到 99.21% 的识别效果,相对于单一特征表达方法下提取到的信号特征进行分类识别提高了 6.8%。

考虑到本文的方法存在一些问题需要解决,如特征融合网络计算量大、训练时间长等,未来可结合轻量化、网络结构改进、训练算法优化和分布式训练等策略,以提升训练效率。

参考文献:

- [1] 杨锋. 基于轻量化神经网络的雷达辐射源识别研究 [D]. 南昌:南昌大学,2023.
- [2] KONG M X,ZHANG J,LIU W F, et al. Radar emitter identification based on deep convolutional neural network [C]//2018 International Conference on Control, Automation and Information Sciences. Hangzhou: IEEE, 2018:309-314.
- [3] 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.
- [4] 任东方,张涛,韩洁. 基于双谱与特征选择的通信辐射源识别算法[J]. 信息工程大学学报,2018,19(4): 410-415.
- [5] 李楠. 基于对角切片特征提取和深度学习的辐射源识别[J]. 电讯技术,2019,59(1):1-6.
- [6] 周春霞. 雷达信号脉内特征提取方法研究[D]. 西安:西安电子科技大学,2014.
- [7] FAN R,SI C K,HAN Y, et al. RFFsNet-SEI: a multidimensional balanced-RFFs deep neural network framework for specific emitter identification[J]. Journal of Systems Engineering and Electronics,2024,35(3): 558-574.
- [8] DING L D,WANG S L,WANG F G, et al. Specific emitter identification via convolutional neural networks[J]. IEEE

- Communications Letters,2018,22(12):2591-2594.
- [9] 杨亮亮. 针对细微特征进行 K-means 聚类的电台分选识别技术[J]. 电讯技术,2022,62(8):1149-1154.
- [10] YU J B,HU A Q,LI G Y, et al. A robust RF fingerprinting approach using multisampling convolutional neural network [J]. IEEE Internet of Things Journal,2019,6(4):6786-6799.
- [11] YU J B,HU A Q,ZHOU F, et al. Radio frequency fingerprint identification based on denoising autoencoders [C]//2019 International Conference on Wireless and Mobile Computing, Networking and Communications. Barcelona:IEEE,2019:1-6.
- [12] 潘一苇,杨司韩,彭华,等. 基于矢量图的特定辐射源识别方法[J]. 电子与信息学报,2020,42(4):941-949.
- [13] 邵峙豪,普运伟. 用于雷达辐射源识别的特殊色彩四维视图[J]. 信息技术,2024,48(1):14-23.
- [14] RAZAVI M,MAVADDATI S,KOOHI H. ResNet deep models and transfer learning technique for classification and quality detection of rice cultivars [J]. Expert Systems with Applications,2024,247:1-13.
- [15] XIE S N,GIRSHICK R,DOLLÁR P, et al. Aggregated residual transformations for deep neural networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu:IEEE,2017:5987-5995.
- [16] 蒋季宏,方宇轩,张伟,等. 小样本情景下基于特征融合的辐射源个体识别[J]. 电子信息对抗技术,2022,37(3):20-25.

作者简介:

余江 男,1998 年生于陕西汉中,2021 年获学士学位,现为硕士研究生,主要研究方向为通信辐射源个体识别。

陈川 女,1981 年生于吉林梅河,博士,教授、硕士生导师,主要研究方向为信号与信息处理、雷达探测技术、智能感知识别。

贾勇 男,1985 年生于山东青州,博士,教授、硕士生导师,主要研究方向为雷达探测技术、人工智能应用。

姚光乐 男,1985 年生于河南三门峡,博士,副教授、硕士生导师,主要研究方向为电磁感知、计算机视觉。

王琛 男,1993 年生于湖北汉川,博士,讲师,主要研究方向为计算机视觉、3D 建模。

张喜娟 女,1980 年生于四川成都,硕士,工程师,主要从事智能信号处理方面的研究。

陈亚锋 男,1986 年生于陕西西安,工程师,主要从事通信天线研发。