

# 数字预失真下的辐射源个体识别技术

赵雅琴<sup>1</sup>, 谢丹<sup>1</sup>, 吴龙文<sup>1</sup>, 丁沁宇<sup>1</sup>, 韩易伸<sup>2</sup>, 张拯华<sup>3</sup>

(1. 哈尔滨工业大学电子与信息工程学院, 黑龙江哈尔滨 150001; 2. 中国空间技术研究院北京空间飞行器总体设计部, 北京 100094; 3. 中国电子科技集团公司第十四研究所, 江苏南京 210039)

**摘要:** 随着通信雷达技术的发展, 针对辐射源发射机的非线性作用出现了预失真等新型技术, 该类技术弱化了不同辐射源的个体特征进而恶化了辐射源个体识别性能. 针对预失真下个体辐射源识别率降低的问题, 本文提出了基于 SincNet 滤波器结构的辐射源个体识别模型. 本文采用 Grad-CAM 方法分析残差网络类激活区域, 并提取共生矩阵特征用于辐射源识别, 验证了预失真后信号局部特征的有效性. 随后本文提出了基于 SincNet 滤波器结构的辐射源个体识别算法, 在降低了计算量的同时, 在低信噪比下具有更高的识别精度. 本文通过实验验证了数字预失真对辐射源个体识别的消极作用, 并且在实测数据上的结果表明所提方法的个体识别率在信噪比 0 dB 下达到 94%, 相比本文其他先进个体识别算法有明显的提升.

**关键词:** 辐射源个体识别; 数字预失真; Grad-CAM; SincNet

**基金项目:** 国家自然科学基金(No.61671185, No.62071153)

**中图分类号:** TN971.41

**文献标识码:** A

**文章编号:** 0372-2112(2023)11-3331-12

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.12263/DZXB.20221122

## Specific Emitter Identification Under Digital Pre-Distortion

ZHAO Ya-qin<sup>1</sup>, XIE Dan<sup>1</sup>, WU Long-wen<sup>1</sup>, DING Qin-yu<sup>1</sup>, HAN Yi-shen<sup>2</sup>, ZHANG Zheng-hua<sup>3</sup>

(1. School of Electronics & Information Engineering, Harbin Institute of Technology, Harbin, Helongjiang 150001, China;

2. Institute of Spacecraft System Engineering, China Academy of Space Technology, Beijing 100094, China;

3. The 14th Research Institute of China Electronics Technology Group Corporation, Nanjing, Jiangsu 210039, China)

**Abstract:** With the development of communication radar technology, new techniques such as pre-distortion have emerged to address the non-linear effects of radiation source transmitters, which weaken the individual characteristics of different radiation sources and thus deteriorate the individual source identification performance. To address the problem of reduced individual source identification under pre-distortion, this paper proposes an individual source identification model based on the SincNet filter structure. This paper uses the Grad-CAM method to analyse the residual network-like activation region and extract the co-occurrence matrix features for radiation source identification to verify the effectiveness of the local features of the signal after pre-distortion. This paper then proposes a SincNet filter structure-based algorithm for individual source identification, which reduces the computational effort while providing higher identification accuracy at low signal-to-noise ratios. The negative effect of digital pre-distortion on the individual identification of radiation sources is verified experimentally and the results on the measured data show that the individual identification rate of the proposed method reaches 94% at a signal-to-noise ratio of 0 dB, which is a significant improvement compared to other advanced individual identification algorithms in this paper.

**Key words:** specific emitter identification; pre-distortion; Grad-CAM; SincNet

**Foundation Item(s):** National Natural Science Foundation of China (No.61671185, No.62071153)

## 1 引言

辐射源个体识别 (Specific Emitter Identification, SEI) 主要依据信号的无意调制特征来实现辐射源的识别区分, 目前被广大学者所关注. 无意调制特征的主要

来源包括频率振荡器的频偏和相位噪声、功率放大器的记忆效应和非线性失真、信号调制器的调制误差和中频、射频滤波器的失真等. 随着 SEI 技术的发展, 基于这些无意调制特征的个体识别方法被相关学者充分

研究,并且可以在各种信道衰减、不同调制方式信号辐射源等特定情况下取得高精度的识别率。

目前辐射源无意调制特征提取方式有3种:基于发射机模型参数的特征提取、基于信号时域或变换域一维特征向量的特征提取、基于二维特征图像的特征提取。史亚等人<sup>[1]</sup>提取不同辐射源特征通过机器学习算法进行多核融合,得到较优的识别效果。冷鹏飞等人<sup>[2]</sup>将辐射源信号包络前沿输入网络,提取不同辐射源的瞬态信息差别,通过卷积神经网络(Convolutional Neural Networks, CNN)提取包络特征,完成个体的识别。黄颖坤等人<sup>[3]</sup>将辐射源信号转化为符号序列,并提取信息熵组成特征向量,使用K近邻算法进行作为分类器,识别结果优于传统特征盒维数以及稀疏性的识别方法。潘一苇等人<sup>[4]</sup>提出以发射机畸变矢量图为信号表示,并使用深度残差网络进行辐射源识别,在保留更多信息的基础上降低复杂度,最终识别率大大提高。秦鑫等人<sup>[5]</sup>采用扩张残差网络进行辐射源识别,对多类辐射源信号具有较高的分类正确率。张敏等人<sup>[6]</sup>以I/Q失配信息作为指纹特征,该特征具有比双谱、Hilbert-Huang变换信号特征提取方法更加优越的性能。

功放非线性失真是辐射源个体识别主要依据之一,但在通信和雷达系统中,功放非线性失真导致线性范围下降以及效率的降低<sup>[7,8]</sup>。随着宽带通信和雷达系统的需求扩大,出现了负反馈、包络跟踪和预失真等功放线性化和提高效率的方法<sup>[9]</sup>。其中,预失真技术<sup>[10]</sup>是适度改善性能的低成本解决方案,与其他线性化技术相比,它利用更简单的电路配置提供了更宽的带宽,已经是基带信号数字预失真技术主流方向之一。预失真技术主要包括割线法、离散牛顿法、最小均方误差算法、RASCAL、递归最小二乘算法等。Muruganathan等人<sup>[11]</sup>提出了基于QR分解的递归最小二乘(QR Decomposition Recursive Least Squares, QRD-RLS)算法来估计表征高功率放大器的无记忆复数多项式系数。云涛<sup>[12]</sup>提出一种自适应变步长的最小均方误差(Least Mean Square, LMS)算法,根据输入信号和误差信号对迭代步长进行自适应调整。张嘉磊<sup>[13]</sup>引入分段线性插值的方法对RASCAL算法进行改进。预失真技术弱化了辐射源的功放非线性特征,进而减弱了辐射源个体识别性能。在功放非线性特征弱化的前提下,显然分类器或者神经网络会更多地聚焦其他个体无意调制特征,比如相位噪声。但是非线性特征弱化依旧会不可避免地降低识别精度。

针对个体特征弱化后的个体辐射源识别问题,本文在预失真技术的基础上进行辐射源个体识别研究,如图1所示。首先,本文研究了基于LMS算法和基于QRD-RLS算法的间接学习数字预失真算法,搭建了半

实物的电磁辐射源平台。其次,本文对数字预失真后无意调制以及信号特性进行了研究,验证预失真技术在减弱信号无意调制的同时,一定程度上仍然保留功放的记忆效应。然后,本文基于围线积分双谱特征(Surrounding-line Integral Bispectrum, Bispec)、水平可视图(Horizontal Visibility Graph, HVG)特征和固有时间尺度分解(Intrinsic Time-scale Decomposition, ITD)特征,利用支持向量机(Support Vector Machine, SVM)分类器分析了预失真技术对个体特征的影响。最后,本文将时频图像输入残差网络进行识别,利用梯度类激活图(Gradient-based Class Activation Mapping, Grad-CAM)进行了敏感性分析,并提出了基于SincNet滤波器结构的辐射源个体识别模型。

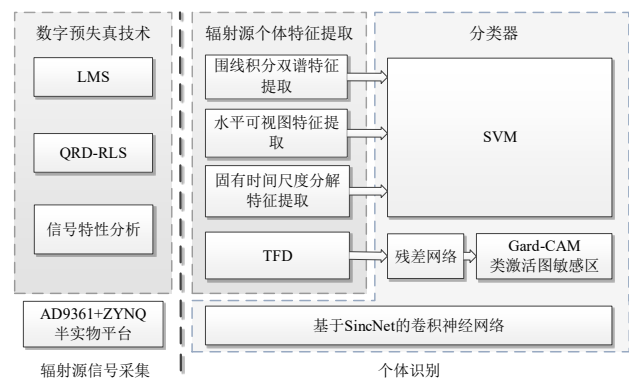


图1 功放数字预失真下的辐射源个体识别研究框图

## 2 相关研究

### 2.1 预失真技术

预失真技术在信号输入功放前做预先“失真”处理,从而在预失真部分的非线性作用达到某种状态时,预失真器和功放的放大系统整体输出信号与原始信号表现为线性放大关系<sup>[14,15]</sup>。预失真原理如图2所示。




图2 数字预失真放大系统原理示意图

图2中 $v_{in}$ 和 $v_{pd}$ 分别为为放大系统和功率放大器的输入信号; $v_{pa}$ 为放大系统的输出信号;三者的功率分别为 $P_{v_{in}}$ 、 $P_{v_{pd}}$ 和 $P_{v_{pa}}$ 。通过增益曲线可以明显看出预失真技术有效补偿了功放增益,使整个放大系统呈线性。本文

主要研究数字预失真技术中的基于 LMS 算法和 QRD-RLS 算法.

LMS 算法是一种随机梯度自适应算法,引入自适应滤波器,通过输入信号的变化迭代调整其权值系数,从而使系统滤波器处于最优,算法框图如图 3 所示.




图 3 LMS 算法框图

图 3 中  $x_i(n)$  为抽头系数  $w_i$  的输入信号,  $d(n)$  是期望输出信号,  $y(n)$  为系统实际输出信号,  $e(n)$  是误差信号且满足式  $e(n) = d(n) - y(n)$ .

QRD-RLS 算法目标是使整体放大系统的实际输出与期望输出间有最小的误差平方和. 若采用记忆多项式 (Memory Polynomial, MP) 模型对功放进行建模, 则此时数字预失真训练器的输出表达式应当为

$$\hat{v}_{pd}(n) = \sum_{k=1}^K \sum_{q=0}^Q w_{kq} \left| \frac{v_{pa}(n-q)}{G} \right|^{k-1} \frac{v_{pa}(n-q)}{G} \quad (1)$$

其中,  $K$  模型阶数;  $Q$  是模型深度;  $G$  是功放增益;  $w_{kq}$  数字预失真器系数.

### 2.2 基于 Grad-CAM 的类激活图敏感性分析

类激活图 (Class Activation Mapping, CAM) 是实现网络输入的敏感性分析的方法, 在进行敏感性分析之前首先需要进行网络训练与测试, 识别精度越高的网络的敏感性分析结果也越准确. 由于预失真后功放特征减弱, 需要对接收信号进行更高阶的特征进行挖掘. CAM 基于全局平均池化层 (Global Average Pool, GAP) 将输出层的权重映射回卷积层, 通过学习权重的大小判断激活区域对分类的重要程度, 实现对网络输入的敏感性分析, 进而截取高敏感性区域实现特征强化. CAM 的示意图如图 4 所示.

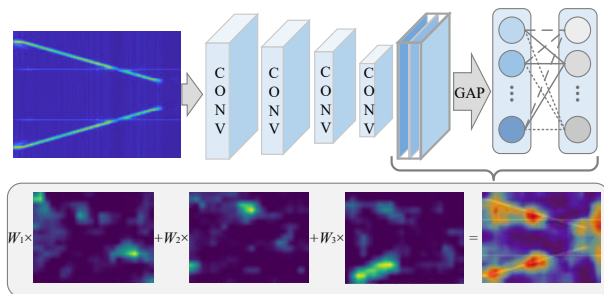


图 4 CAM 示意图

假设  $c$  类输入样本  $x^c$  和含有 GAP 层的卷积神经网络. 设网络中最后的卷积层生成的  $k$  个特征图  $A^k$  为

$$A^k = f_{act}(W \otimes x^c + b) \quad (2)$$

其中,  $W$  和  $b$  分别是分类层神经元的权重和学习偏置;  $f_{act}$  为网络的非线性激活函数.

将最后一个卷积层第  $k$  个单元在  $(i, j)$  位置处的激活值设为  $A_{i,j}^k$ , 经过 GAP 层的累加计算结果  $A_{GAP}^k$  为

$$A_{GAP}^k = \sum_{i,j} A_{i,j}^k \quad (3)$$

忽略输出层的偏置项, GAP 层输出特征图经过网络输出层有

$$y^c = \sum_k W_{out}^c A_{GAP}^k \quad (4)$$

其中,  $W_{out}^c$  为输出层单元对应  $c$  类的学习权重定义, 其反映了  $A_{GAP}^k$  对于分为  $c$  类的重要程度;  $y^c$  为输出类别为  $c$  类的得分值.

将式 (3) 代入式 (4) 可得

$$\begin{aligned} y^c &= \sum_k W_{out}^c \sum_{i,j} A_{i,j}^k \\ &= \sum_{i,j} \sum_k W_{out}^c A_{i,j}^k \\ &= \sum_{i,j} M_{i,j}^c \end{aligned} \quad (5)$$

其中,  $M_{i,j}^c$  为输入样本  $x^c$  经过该网络的 CAM, 表示了样本  $x^c$  上  $(i, j)$  位置处的激活程度, 即敏感程度.

由于 CAM 方法存在对 GAP 层权重的依赖性, 使用时需改变原网络结构. 为克服该缺点, 采用 CAM 的改进型 Grad-CAM<sup>[16]</sup>, 利用反传梯度表示权重.

定义第  $k$  个特征图对应目标类别  $c$  的权重为

$$\alpha_k^c = \frac{1}{Z} \sum_i \sum_j \frac{\partial y^c}{\partial A_{i,j}^k} \quad (6)$$

其中,  $Z$  代表像素总数.

前向特征图的加权组合, 通过 ReLU 激活函数获得样本  $x^c$  经过该网络的类激活图函数为

$$L_{Grad-CAM}^c = \text{ReLU} \left( \sum_k \alpha_k^c A^k \right) \quad (7)$$

其中,  $L_{Grad-CAM}^c$  是网络对原始输入时频图的激活程度, 值越大, 代表网络对该位置的激活程度越大. 最后以热力图的形式与时频图样本叠加显示, 红色区域就代表了网络对输入样本该区域的关注度更高.

本文首先采用时频分析方法表征不同辐射源个体的时频分布 (Time Frequency Distributed, TFD), 然后将时频变换得到的信号时频图输入深度残差网络 (Residual Network, ResNet) 进行识别, 最后通过 Grad-CAM 观察残差网络类激活图敏感区域, 判断输入时频图不同区域对识别的贡献程度. 通过截取高敏感性区域进行辐射源个体识别来增强神经网络可解释

其,并验证预失真后信号局部特征对于辐射源识别的有效性.

### 3 基于 SincNet 的辐射源个体识别

在基于深度学习的识别算法中,本文将大致分为两类:一类为通过变换提取图像特征,输入 ResNet, VGG, GoogLeNet 等神经网络进行识别;另一类直接输入时序信号,通过网络对其进行特征提取,通常首先训练自编码模型,然后采用循环神经网络(Recurrent Neural Network, RNN)、长短期记忆网络(Long Short Term Memory, LSTM)等网络加以识别.由于敏感区域的复杂性,其应当是不规则且离散的区域,可以采用神经网络进行高精度提取.考虑信号时域存在的不确定性较大,将提取时频图高敏感区域进一步简化为提取频率高敏感性区域,这一行为可等价于滤波.受到局部敏感区域可以增强辐射源个体识别的启发,本文提出基于 SincNet 滤波器结构的辐射源个体识别算法,利用 CNN 直接对时序信号进行识别,为辐射源个体识别提供了一种新的思路.

对于输入为时序信号的网络,标准 CNN 的第一层在输入波形之间执行一组时域卷积,定义:

$$y[n] = x[n] * h[n] = \sum_{l=0}^{L-1} x[l] \cdot h[n-l] \quad (8)$$

其中,  $x[n]$  是输入信号,  $h[n]$  是长度为  $L$  的滤波器,  $y[n]$  是滤波器输出,在标准的 CNN 结构中,每个滤波器的  $L$  个元素都是从数据中学习得到的.

基于一维时间序列的 CNN 结构中最关键的部分之一是第一卷积层,该层不仅处理高维输入,在采用非常深的体系结构时更容易受到梯度消失的影响.为了帮助 CNN 在输入层中发现更有意义的信息, SincNet 在标准的 CNN 结构中添加了一些约束,直接将时间序列与一组实现带通滤波器的参数化 sinc 函数进行卷积,仅从数据中学习滤波器的低截止频率和高截止频率.

在 SincNet 结构中,通过预定义的带通滤波器函数  $g$  与输入信号序列进行卷积操作,其中可学习变量  $\theta$  数量很少,卷积后输出:

$$y[n] = x[n] * g[n, \theta] \quad (9)$$

带通滤波器函数  $g$  函数的频域特性:

$$G[n, f_1, f_2] = \text{rect}\left(\frac{f}{2f_2}\right) - \text{rect}\left(\frac{f}{2f_1}\right) \quad (10)$$

其中,  $f_1$  和  $f_2$  分别为低截止频率和高截止频率,两者都是可学习的.

经过逆傅里叶变换,转化为时域表达式为

$$g[n, f_1, f_2] = 2f_2 \text{sinc}(2\pi f_2 n) - 2f_1 \text{sinc}(2\pi f_1 n) \quad (11)$$

其中, sinc 函数定义为  $\text{sinc}(x) = \sin(x)/x$ .

本文将滤波器的起始频率初始化为均匀分布在  $[0, f_s/2]$  范围内,  $f_s$  为信号的采样率,带宽设置成起始频率间的差值.由于存在频谱泄漏问题以及在 SincNet 结构中窗函数的选择对识别效率影响不大,故选择汉明窗函数抑制即可.汉明窗函数为

$$\omega[n] = 0.54 - 0.46 \cos\left(\frac{2\pi n}{L}\right) \quad (12)$$

加窗后的滤波器为

$$g_\omega[n, f_1, f_2] = g[n, f_1, f_2] \cdot \omega[n] \quad (13)$$

通过式(9)和 CNN 的卷积层结构,自适应修改带通滤波器高低截止频率,即可完成 SincNet 网络的构建. SincNet<sup>[17]</sup> 滤波器结构实质上是在网络第一层滤波提取更有效的低维特征,以实现提取频率敏感性区域,其与类激活图进行敏感性分析并选取敏感性区域的行为,具有一致的目的.

本文使用的基于 SincNet 滤波器结构的辐射源个体识别模型如图 5 所示.在 60 MHz 采样率下,网络的第一层 SincNet 为共 80 维的滤波器结构,每个滤波器起始带宽约为 0.37 MHz,结构起始频率和截止频率从 0 到 30 MHz 连续分布.在此基础上利用窗口大小为 3 的池化层进行降维,输出经过两对卷积核大小为  $5 \times 5$  的卷积层以及窗口大小 3 的池化层,嵌入样本底层特征,再经 4 个全连接层.在全连接层后又设置了 BN 层,采用 LeakyReLU 激活函数,设置 Dropout 比率为 0.5,最后经 softmax 层归一化后完成预失真后辐射源个体信号识别,具体的网络参数如表 1 所示.

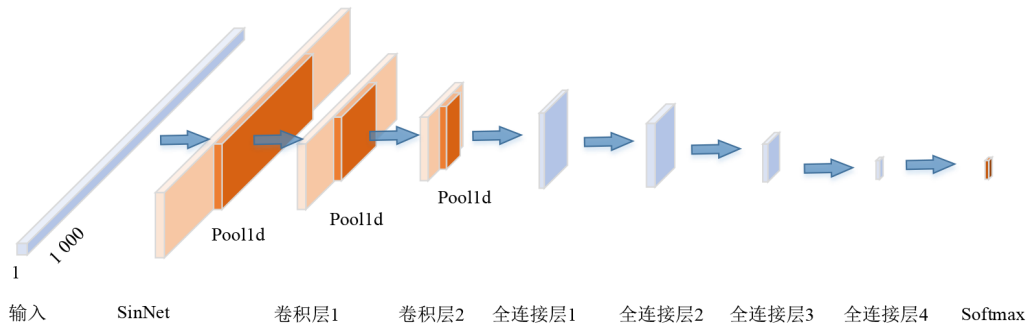


图 5 基于 SincNet 滤波器结构的辐射源个体识别模型

表 1 基于SincNet的辐射源个体识别模型的网络结构

网络层	参数	输出尺寸
输入层	—	(Batch, 1, 1 000)
SincNet层	维度=80; $f_s = 60$ MHz	(Batch, 80, 332)
池化层	3 × 3; max pool	(Batch, 60, 109)
卷积层 1	conv(5 × 5, 60); Laynorm; Leaky-Relu	(Batch, 60, 109)
池化层	3 × 3, max pool	(Batch, 60, 65)
卷积层 2	conv(5 × 5, 60); Laynorm; Leaky-Relu	(Batch, 60, 65)
池化层	3 × 3, max pool	(Batch, 60, 35)
全连接层 1	fc(2 100 × 1 028); Batchnorm; Leaky-Relu	(Batch, 1 028)
全连接层 2	fc(1 028 × 512); Batchnorm; Leaky-Relu	(Batch, 512)
全连接层 3	fc(512 × 128); Batchnorm; Leaky-Relu	(Batch, 128)
全连接层 4	fc(128 × 3);	(Batch, 3)
Softmax层	—	(Batch, 3)

## 4 实验

### 4.1 实物辐射源平台构建

本文使用 Xilinx 公司 ZYNQ-7000 系列开发板作为主控,搭建半实物辐射源平台,利用功放数字预失真算法对采集数据进行处理,使在本文研究中的验证更加贴近于实际. 本文主要针对于数字预失真下的辐射源进行识别,在半实物辐射源平台的基础上,需要进行数字预失真,搭建框图如图 6 所示.

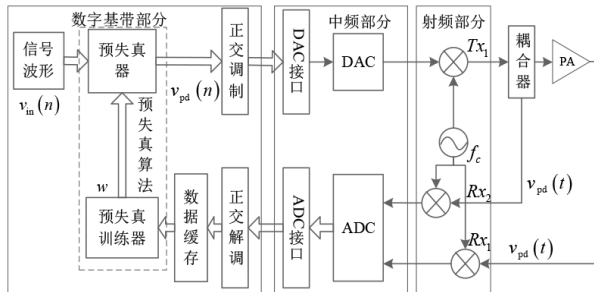


图 6 半实物辐射源平台搭建图

本文所用仿真信号调制方式分别为线性调频(Linear Frequency Modulation, LFM)和正交相移键控(Quadrature Phase Shift Keying, QPSK),具体信号参数配置如表 2 所示. 其中 LFM 信号起始频率为 2 MHz,带宽为 10 MHz,脉冲宽度为 15  $\mu$ s,周期为 25  $\mu$ s; QPSK 信号的数据传输速率为 25 Mbps,滚降系数为 0.22. 接收机的接收中心频率设置为 2.4 GHz,接收带宽设置为 60 MHz,下变频后 ADC 采样率为 60 Msps.

为更加深入地研究功放模块的非线性作用,本文利用低噪声射频功率放大芯片设计了功率放大器模块. 电路原理图如图 7 所示,PCB 设计和输入信号进行测试环境如图 8 所示.

为区分不同辐射源个体,并且更具针对性地研究

表 2 信号参数配置

信号	调制方式	基带中频	载波频率
S1	线性调频	7 MHz	2.4 GHz
S2	线性调频	7.5 MHz	2.4 GHz
S3	线性调频	11 MHz	2.4 GHz
S4	QPSK	3.5 MHz	2.4 GHz

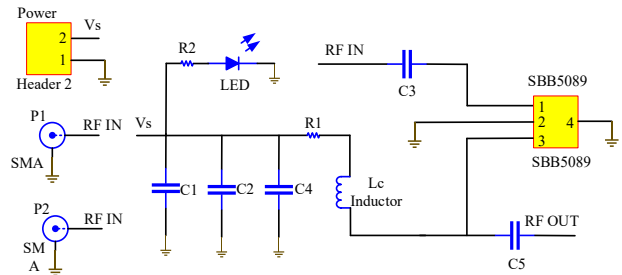


图 7 功率放大器原理图




图 8 功放模块 PCB 板及测试环境

功放预失真对辐射源个体识别造成的影响,在控制 AD9361 和 ZYNQ 软件无线电平台和输出信号不变的基础上,分别采用不同射频放大器模块,增益均在 20 dB 左右,输入输出阻抗 50  $\Omega$ ,在中心频率 2.4 GHz,带宽 10 MHz 下可以对输入的 LFM 和 QPSK 信号完成放大作用. 各辐射源个体 SE1, SE2 和 SE3 的配置及参数如表 3 所示.

表3 辐射源平台的配置及参数列表

个体	放大器	放大器芯片型号	2.4 GHz增益/dB
SE1	PA1	SBB5089ZP48G	15.0
SE2	PA2	SBB5089ZP1YY	18.7
SE3	PA3	SPF5043ZEVBI	20.7

## 4.2 数字预失真算法性能分析

从采集信号中随机抽取一组,选用S4-SE1和S1-SE3的LMS和QRD-RLS预失真信号.在相同输入信号条件下,对半实物仿真信号进行单次预失真的处理.本文使用误差向量幅度(Error Vector Magnitude, EVM)和邻近信道功率比(Adjacent Channel Power Ratio, ACPR)两个客观指标来对两种预失真算法频谱结果进行评价.

EVM为期望信号与实际输出信号误差向量归一化均方根值,可表示为式(14).其中 $N$ 为一段时间内离散信号的采样点数, $e_k$ 为误差向量,本文采用平均功率 $P_{\text{avg}}$ 作为归一化标准.在本文背景下,EVM越小,表示预失真后输出信号越接近于输入信号,预失真算法越好.

$$\text{EVM} = \sqrt{\frac{1}{N} \sum_{k=1}^N (e_k)^2} / P_{\text{avg}} \quad (14)$$

本文通过ACPR从频域上对预失真算法进行评价.

$$\text{ACPR} = 10 \times \lg \frac{P_{\text{adj}}}{P_{\text{main}}} \quad (15)$$

其中, $P_{\text{main}}$ 和 $P_{\text{adj}}$ 分别是功放输出信号发射频率和扩展频率的平均功率,两者的比值可以对信号频谱扩展现象进行表征.ACPR越小,表示预失真算法效果越好.在过采样因子为1的情况下,计算两种预失真算法所得输出信号在15~24 MHz临道功率比和其误差向量幅度如表4所示.

表4 辐射源信号经数字预失真校正前后性能指标变化情况

调制方式	预失真算法	ACPR/dB	EVM
QPSK	无	-31.2	0.145
	LMS	-31.9	0.148
	QRD-RLS	-33.2	0.111
LFM	无	-23.8	0.181
	LMS	-24.8	0.188
	QRD-RLS	-26.1	0.122

在EVM评价下,LMS算法效果不够理想,而通过ACPR可得,QRD-RLS算法的结果在所选15~24 MHz频段上的功率比最小.在两种调制方式下,QRD-RLS算法和LMS算法对功放的非线性作用均有所抑制,相比LMS算法,QRD-RLS算法计算简单快速,输出信号效果较为理想,同时也是实际工程中常用的一种数字预

失真的算法,后续实验如果不做特殊说明,本文数字预失真后输出信号都是采用基于QRD-RLS的数字预失真算法获得的.

## 4.3 预失真技术对辐射源个体识别的影响

在半实物仿真数据集内加入加性高斯白噪声,噪声信噪比范围为-5~25 dB.为了验证数字预失真技术对SEI的性能影响,本文提取信号的Bispec特征、HVG特征、ITD等SEI领域的经典特征,利用SVM分类器进行分类.输入S1-SE1,S1-SE2和S1-SE3辐射源信号,包括500个样本,每个样本包括10个脉冲,将样本按7:3的比例随机分成训练集和测试集,归一化后利用网格搜索的方法对SVM进行参数寻优,得到最后的识别率.

为了分析不同预失真技术对辐射源个体识别的影响,本文以Bispec特征为例,对比QRD-RLS预失真与LMS预失真算法对个体识别率的影响程度.基于LMS和QRD-RLS预失真算法的SEI结果如图9所示,不同预失真技术下的辐射源个体识别率均有所下降.

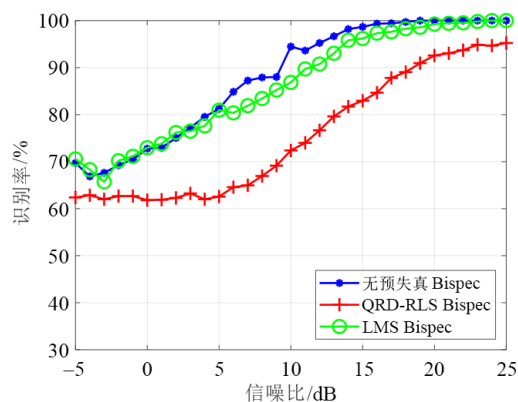



图9 不同预失真技术前后个体识别结果

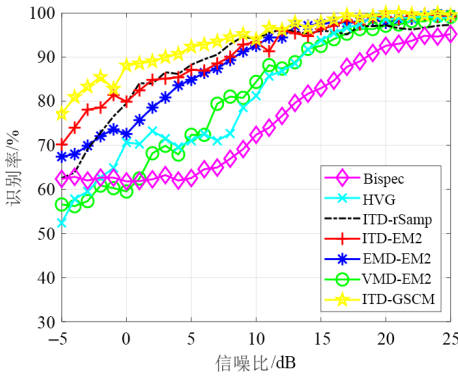
对比QRD-RLS预失真与LMS预失真算法对个体识别率的影响程度,可以看出,LMS预失真算法识别率相比无预失真略有下降,然而QRD-RLS算法识别率却有明显下降.在-5~5 dB低信噪比下,识别率保持在60%左右,结合第4.2节分析内容可以发现,预失真算法效果越好,对辐射源个体识别率的影响程度越大,表明数字预失真下辐射源个体识别具有研究价值.

基于围线积分双谱特征、水平可视图特征和固有时间尺度分解的辐射源个体识别结果如图10所示,可以看出预失真前后的识别率均有明显下降,说明预失真技术本身是对个体识别效果起到削弱作用的,尤其是在低信噪比下,表明功放数字预失真下辐射源个体识别具有研究价值.本文从时频变换得到特征图像中进一步提取熵和一阶二阶矩(Entropy and First and Second-Order Moments, EM<sup>2</sup>)特征、灰度-平滑共生矩阵(Gray Smooth Cooccurrence Matrix, GSCM)等特征,并且将样本熵特征与相关系数特征组合得到辐射源的个体

特征向量(rSamp). 本文利用ITD信号分量的时频能量分布谱提取EM<sup>2</sup>特征,并与EMD和VMD下的效果进行比较分析.



(a) 无预失真下识别率



(b) 预失真后识别率

图 10 多特征对预失真后个体识别结果

由图 10 可知,相比 EMD-EM<sup>2</sup> 特征和 VMD-EM<sup>2</sup> 特征,基于 ITD-EM<sup>2</sup> 特征的 SEI 取得了最优的识别效果,同时在预失真下的识别性能恶化最为严重. 由于 ITD 在 SEI 中拥有抗噪、稳定性高等优势,本文进一步提取 ITD-rSamp 特征和 ITD-GSCM 特征,在低信噪比 -5 dB 下,ITD-GSCM 特征识别率下降最少;在整个信噪比范围下进行分析,ITD-GSCM 特征的识别率下降最少,受预失真影响最小. 从图 10(a)可知,本文所使用的传统特征都表现出较高的识别率,尤其在较低信噪比 -5~5 dB 下,多数特征的个体识别率达到 80% 以上. 但是在预失真后的功放系统中,如图 10(b)所示,只有部分特征可以保持较高识别率,在 -5~5 dB 信噪比条件下多数特征个体识别率只能达到 60%,所有特征在预失真后的识别精度都出现了不同程度的恶化.

各特征在有无预失真下识别性能具体恶化情况如表 5 所示,可以看出基本上所有特征在所选信噪比范围内的识别性能都出现了不同程度的恶化,在 5 dB 下多数特征识别率下降了 10% 以上,HVG 和 EMD-EM<sup>2</sup> 特征

在 25 dB 出现负值,此时识别率很大故而忽略不计. 基于 EM<sup>2</sup> 特征、rSamp 特征和 GSCM 特征的 SEI 识别率普遍高于基于 Bispec 特征和 HVG 特征的 SEI 识别率,由此可知,提取信号 TFD 的纹理特征可以缓解预失真引起的识别性能下降.


表 5 各特征在有无预失真下识别性能恶化对比 单位:%

个体特征	-5 dB	5 dB	15 dB	25 dB
Bispec 熵特征	7.33	18.70	15.7	4.76
HVG 相关性、熵特征	28.60	19.60	3.52	-0.09
ITD-EM <sup>2</sup>	15.60	12.70	3.62	0.76
EMD-EM <sup>2</sup>	9.24	3.53	1.90	-0.38
VMD-EM <sup>2</sup>	7.62	20.50	6.86	0.29
ITD-rSamp	19.30	11.20	3.05	2.19
ITD-GSCM	5.71	5.71	0.24	0.47


为了进一步分析预失真技术对辐射源个体识别的影响,本文以 HVG 特征为例,可视化了预失真前后水平可视图特征分布,如图 11 所示. 从图中可以看出在预失真后 S1-SE1, S1-SE2 和 S1-SE3 的 HVG 特征类别可分性明显降低. 根据功放个体特征矩阵,利用式(16)求得欧式距离下的可分性判据  $J$ ,即

$$J_d(x) = \text{tr}(\mathbf{S}_b) / \text{tr}(\mathbf{S}_w) \quad (16)$$

其中,  $\mathbf{S}_w$  和  $\mathbf{S}_b$  分别是总的类内和类间离散度矩阵.



(a) 预失真前 HVG 特征



(b) 预失真后 HVG 特征

图 11 预失真前后 HVG 特征分布

在无预失真的条件下类别可分性判据  $J$  为 0.003 0,而在经过预失真处理后,两功放的  $J$  为 0.001 1,出现明显下降,进一步验证了数字预失真技术对辐射源个体

识别造成了困难. 因此特征敏感性与类别可分性, 即识别有效性, 不完全一致, 本文主要对特征的有效性进行研究. 信号瞬时频率的能量熵明显减小, 可知其混乱程度变小.

从以上分析可知, 传统个体识别特征难以完全解决预失真技术带来的个体识别性能恶化的问题. 本文考虑利用对信号局部区域敏感的分类器来解决预失真技术带来的性能恶化问题, 提出基于残差网络类激活图的辐射源个体识别方法.

#### 4.4 残差网络类激活图敏感性分析

针对引入预失真技术后识别恶化现象, 本文提出基于残差网络类激活图的辐射源个体识别方法. 本文先采用希尔伯特黄变换 (Hilbert-Huang Transform, HHT)、Choi-Williams 变换 (Choi-Williams Distributions, CWD)、连续小波变换 (Continuous Wavelet Transform, CWT) 等得到输入信号的时频特征图, 然后输入至残差网络进行辐射源识别, 再引入 Grad-CAM 提取类激活图, 分析网络敏感区域, 最后将截取的时频图敏感区域输入至残差网络进行辐射源识别, 得到最终的辐射源识别结果.

##### 4.4.1 基于残差网络的辐射源个体识别验证

本文采用的残差网络引入了二元自适应均值汇聚层, 自适应地根据输入来调整参数. 本文首先将辐射源信号进行小波去噪, 然后分别经过 CWD, ITD, CWT, HHT 得到信号时频图, 再输入至残差网络进行训练和测试. 本文设置每个信噪比下三类辐射源信号共 4 500 组脉冲数据, 训练集和测试集比例为 2:1. 并且, 设置根据迭代数调整学习率, 设置负对数似然损失函数, 采用随机梯度下降优化器进行优化.

本文使用固定大小的时频图作为深度神经网络的输入样本, 样本尺寸不仅影响识别效果, 而且也影响着算法的复杂度. 由于在信噪比较低时, 图像特征对样本尺寸的变化更敏感, 因此本文在信噪比为 -5 dB 时, 使用不同尺寸大小的 CWD, ITD, CWT 时频图输入至 ResNet50 网络, 实验结果如图 12 所示. 当时频图尺寸过小时, 网络无法完全提取到图像的局部特征, 信息量较小, 识别精度较低. 当样本尺寸变大时, 识别精度逐渐提高, 但是当图像尺度过大时, 网络在运算复杂度增大的同时, 识别率反而会降低. 由图 12 可知, 当输入是尺寸为 500×500 的信号时频图时, 基于 ResNet50-CWD 的 SEI 模型取得了最优的性能.

本文以 500×500 的信号时频图作为输入, 计算多种不同特征在 ResNet 网络下的识别精度, 如表 6 所示, 其中利用信号 CWD 时频图进行个体识别相较于其他变换效果更好. 其次, 本文对比了使用不同残差网络层数的结果, 基本相差不大. 故此, 本文采用 CWD 时频图以及 ResNet50 进行类激活图分析.




图 12 在不同输入尺寸下基于 ResNet50 模型的识别精度

表 6 各网络模型在不同信噪比下识别精度 单位: %

模型	-5 dB	0 dB	5 dB	10 dB	15 dB	20 dB	25 dB
ResNet50-CWD	73.2	85.9	91.3	96.1	98.1	99.3	99.7
ResNet50-HHT	52.3	69.0	84.3	88.5	91.3	93.9	93.9
ResNet50-ITD	54.6	76.1	86.5	89.3	93.2	96.3	96.7
<b>ResNet50-CWD</b>	<b>81.3</b>	<b>90.9</b>	<b>94.2</b>	<b>98.2</b>	<b>99.6</b>	<b>100.0</b>	<b>100.0</b>
ResNet34-CWD	80.3	89.8	94.6	98.2	99.4	99.9	99.9
ResNet101-CWD	81.6	88.9	94.7	97.2	99.3	99.9	99.9

注: 粗体数据表示在 ResNet 网络下多种不同特征在不同信噪比下的最优识别精度.

##### 4.4.2 残差网络类激活图敏感性分析

首先将预失真后的信号进行 CWD 变换后得到 CWD 时频图, 然后输入至训练后的 ResNet50-CWD 网络中, 再将分类权重通过激活函数反向传播回输入时频谱图, 最后通过 Grad-CAM 得到训练后网络的类激活图, 如图 13 所示.

图 13 中红色区域代表该区域分类权重大的部分, 其对网络识别起到了重要作用. 可以发现红色区域主要沿着时频图的主信号时频部分分布, 而蓝色区域主要分布在非主频的噪声部分, 可见 Grad-CAM 方法对时频图敏感区域的分析是有实际物理意义的. 本文观察分析了辐射源 SE1~SE3 各 500 样本下敏感区域的分布, 发现同一个体不同样本的敏感区域趋同, 而各个辐射源敏感区域分布位置明显不同, 以 SE1 和 SE2 为例, SE1 的类激活图主要敏感区域分布在调制的边缘部分, 而 SE2 主要分布于中频部分.

本文对敏感区域局部信息的特征进行二次分析, 针对 SE1 的类激活图敏感区域, 截取 CWD 时频图相应区域, 探讨预失真后辐射源信号在敏感区域处局部特征的可分性, 如图 14 所示. 将 CWD 时频图的敏感区域各通道求和后取平均, 绘制出两通道的时频图像.

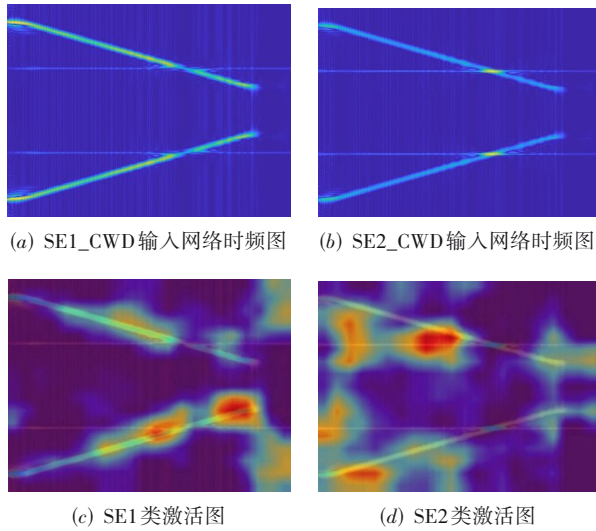


图 13 Grad-CAM 结果图

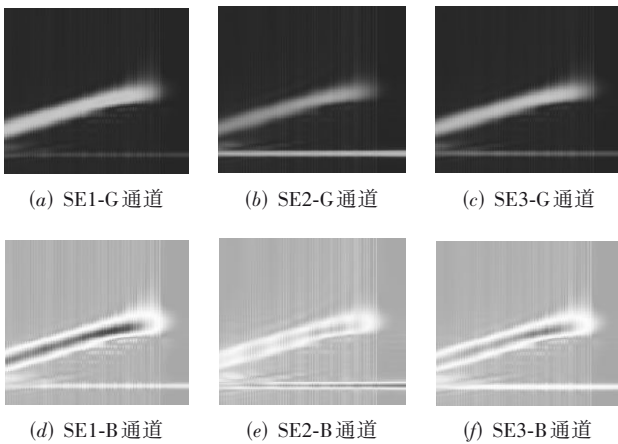


图 14 各辐射源敏感区域均值图

可以发现针对不同辐射源,敏感区域差异明显,尤其是B通道.不同于调制方式识别等人眼可观察到的图像特征,基于Grad-CAM的辐射源个体识别可视化模型可以捕捉到人眼难以察觉到的特征或个体差异明显的区域.

各个辐射源在数字预失真下的敏感区域瞬时频率图像如图 15 所示.可以看出在这段敏感区域中,调制部分的SE1时频能量没有很好地聚集,方差比较大,而未调制部分影响不大,在CWD时频图中灰度值一直保持较低,非蓝色区域的范围较大,因此B通道的平均灰度较低;SE2在调制部分的时频聚集能力最强,故而其敏感区域的时频方差最小,正因为为主频段上的聚集,使得其B通道平均灰度比较大;SE3的时频聚集性在SE1与SE2之间,SE3的B通道平均灰度、G通道方差都介于SE1和SE2间.整体结果与图 14 结果一致.

#### 4.4.3 基于敏感区域的辐射源个体识别验证

本文截取了辐射源SE1~SE3的CWD时频图敏感




图 15 敏感区域瞬时频率图

区域,并根据上一节分析,计算CWD时频图敏感区域B通道的平均灰度和G通道的方差,聚类后得到的结果如图 16 所示.可以明显发现,辐射源个体之间具有较强的可分性.

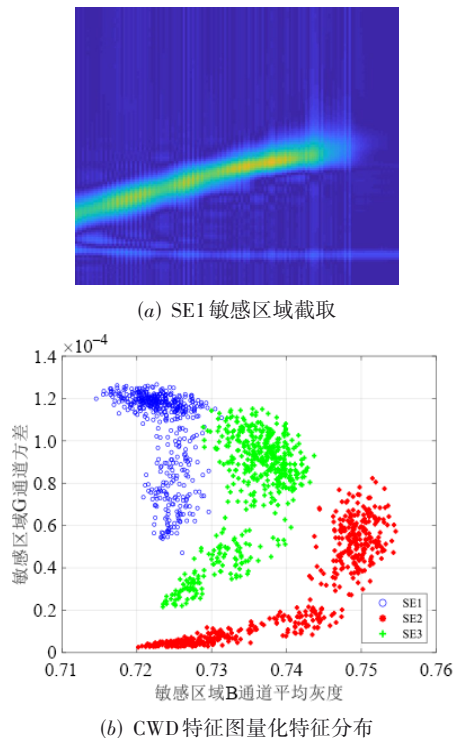


图 16 通过敏感区域进行识别

为了进一步证明以局部特征即敏感区域特征作为辐射源个体识别特征的可行性,本文将预失真辐射源 SE1~SE3 信号样本转换为 CWD 时频图,提取敏感区域时频图的灰度共生矩阵为特征,以 SVM 为分类器,并且对比了其他传统特征在 SVM 下的识别精度,实验结果如表 7 所示.

表 7 不同特征下采用 SVM 的识别精度 单位:%

特征	灰度共生矩阵	灰度共生矩阵	一阶二阶矩	水平可视图	
区域	敏感	全局	全局	全局	
信噪比	-5 dB	63.9	73.1	70.2	52.4
	0 dB	82.9	88.8	79.9	70.7
	5 dB	90.9	94.2	87.1	71.0
	10 dB	95.8	98.1	93.4	81.2
	15 dB	98.0	99.4	96.4	93.8
	20 dB	99.2	99.8	99.1	98.6
	25 dB	99.9	99.8	99.2	99.0

结果表明采用高敏感性区域识别可以在高信噪比下获得与采用全部区域识别相当的识别精度,但在低信噪比下,识别精度会急剧降低,-5 dB 时下降了 9.2% 的识别精度. 该结果是合理的. 因为本节中使用的高敏感性区域是通过观察分析后手动截取的矩形窗口,并非是完全正确的,必然会导致信息的损失. 实际上,真实的敏感区域应当是不规则的、离散的区域. 手工截取的敏感性区域在高信噪比条件下也具有较高的精度,证明了类激活图分析敏感性区域并用于 SVM 识别的有效性. 在低信噪比下,由于噪声影响太大,类内离散度上升,同时预失真后本就细微的区别更容易被噪声淹没,故而识别精度快速下降.

在低信噪比下,手动截取敏感性区域的性能较低,进而本文提出了基于 SincNet 滤波器结构的辐射源个体识别方法,通过神经网络自动提取输入信号的敏感性区域,实现更高精度的敏感性区域截取.

#### 4.5 基于 SincNet 结构的辐射源个体识别

本文利用基于 SincNet 滤波器结构的神经网络对输入数字预失真后的辐射源信号进行个体识别. 如图 5

所示,该模型的输入为一维时间序列,第一层 SincNet 的输出为学习到的滤波器频段即为信号敏感频率,模型输出为辐射源个体识别结果. 本文在 S1-SE1, SE2, SE3 各 500 样本共 1 500 样本下的脉冲采样点进行训练,采用同样 1 500 样本不同时间段的脉冲采样点进行测试. 设置自适应的学习率函数, Batch 为 32, 利用 RMSprop 优化器训练.

考虑到输入样本点数对辐射源个体识别率的影响,本文在信噪比为 -5 dB 时,设置基于 SincNet 滤波器结构的辐射源个体识别模型的样本点数以 200 为步长,从 600 至 2 000 变化的实验结果如图 17 所示. 从图 17 中可以看出,随着样本点数的增加,信号样本所包含的特征也逐渐增多,其识别精度也逐步提高. 当样本点数从 800 到 1 000 变化时,识别精度有明显的增强;当维度从 1 000 到 2 000 变化时,识别精度也在稳步缓慢提高,始终保持较高的识别精度. 考虑到实际应用场景中信号采集较为困难和输入维度增加带来的运算量增大的问题,本文设置后续 SincNet 滤波器的输入样本点数为 1 000.




图 17 不同输入维度下的基于 SincNet 结构的 SEI 精度

在不同信噪比下,本文提出基于 SincNet 滤波器结构的辐射源个体识别模型的结果,如表 8 所示,并且对比了其他模型. SincNet 滤波器结构实现了精确的敏感性区域选取,可以较好地滤除噪声的干扰,所以在低信噪比下具有较好的结果,整体结果与上文分析相比,呈现一致性.

表 8 不同网络在不同信噪比下识别精度

单位:%

模型	-5 dB	0 dB	5 dB	10 dB	15 dB	20 dB
Vgg16-CWD	75.7	83.7	86.5	88.5	87.7	88.9
DCBAM-ResNet50-CWD	77.7	86.4	95.5	93.3	92.2	99.3
ResNeXt50-CWD	82.7	91.1	95.9	99.2	99.8	100.0
DenseNet121-CWD	81.7	90.7	94.7	98.5	99.7	100.0
<b>SincNet</b>	<b>89.3</b>	<b>94.2</b>	<b>97.9</b>	<b>99.3</b>	<b>99.9</b>	<b>100.0</b>

注:粗体数字表示不同网络在不同信噪比下的最优识别精度.

结合表5与表6可以看出,本文提出的SincNet模型与对比方法中最精确的ResNeXt50-CWD相比,在强噪声下辐射源个体识别中识别精度具有明显的优势,在-5 dB时提高了6.57%的精度,在增加深度学习网络可解释性的同时,具有较高的识别率且稳定性较强,可以有地缓解数字预失真技术带来的辐射源个体识别性能下降,并且具有较强的鲁棒性。

在实际应用于数字预失真下辐射源个体识别中,还需要考虑模型参数量和计算量,因此本文还对比了ResNeXt50-CWD模型和SincNet模型的算法浮点运算总数和模型参数总量,如表9所示。从表中可得,ResNeXt50-CWD模型的运算量和参数量远大于SincNet模型,这是由于SincNet模型在第一层直接滤波,使模型更多地关注敏感性区域,降低了网络复杂度。

表9 运算量对比

方法	识别精度 (0 dB)/%	浮点运算 总数	模型参数 总量
ResNeXt50-CWD	91.1	$4.2 \times 10^9$	$2.5 \times 10^7$
SincNet	94.2	$2.4 \times 10^9$	$1.3 \times 10^7$

综上所述,本文提出的基于SincNet滤波器结构的辐射源个体识别模型在保证较低计算量的同时获得高精度的识别性能,可以有效地缓解数字预失真技术带来的辐射源个体识别性能下降。

## 5 结论

针对预失真下辐射源个体特征减弱的问题,本文提出了基于SincNet结构的辐射源个体识别算法。首先,本文研究了基于LMS和QRD-RLS的预失真算法并利用AD9361和ZYNQ构建了辐射源平台。然后,本文基于围线积分双谱特征、水平可视图特征和固有尺度分解特征,证明了预失真技术会明显削弱辐射源个体特征,降低个体识别性能,并且预失真技术越好,削弱效果越明显。接着,本文进行了残差网络类激活图敏感性分析,提出了基于敏感区域的辐射源个体识别,验证了以局部特征即敏感区域特征作为辐射源个体识别特征的可行性。最后,鉴于在低信噪比下手动截取的敏感性区域识别精度不足,本文提出了基于SincNet结构的辐射源个体识别模型。实验证明,与其他算法相比,该模型在保证较低计算量的同时获得高精度的识别性能,可以有效地缓解数字预失真技术带来的辐射源个体识别性能下降。

## 参考文献

[1] 史亚, 姬红兵, 朱明哲, 等. 多核融合框架下的雷达辐射源个体识别[J]. 电子与信息学报, 2014, 36(10): 2484-2490.

SHI Y, JI H B, ZHU M Z, et al. Specific radar emitter identification in multiple kernel fusion framework[J]. Journal of Electronics & Information Technology, 2014, 36(10): 2484-2490. (in Chinese)

[2] 冷鹏飞, 徐朝阳. 一种深度强化学习的雷达辐射源个体识别方法[J]. 兵工学报, 2018, 39(12): 2420-2426.

LENG P F, XU C Y. Specific emitter identification based on deep reinforcement learning[J]. Acta Armamentarii, 2018, 39(12): 2420-2426. (in Chinese)

[3] 黄颖坤, 金炜东, 葛鹏, 等. 基于多尺度信息熵的雷达辐射源信号识别[J]. 电子与信息学报, 2019, 41(5): 1084-1091.

HUANG Y K, JIN W D, GE P, et al. Radar emitter signal identification based on multi-scale information entropy[J]. Journal of Electronics & Information Technology, 2019, 41(5): 1084-1091. (in Chinese)

[4] 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.

PAN Y W, YANG S H, PENG H, et al. Specific emitter identification using signal trajectory image[J]. Journal of Electronics & Information Technology, 2020, 42(4): 941-949. (in Chinese)

[5] 秦鑫, 黄洁, 查雄, 等. 基于扩张残差网络的雷达辐射源信号识别[J]. 电子学报, 2020, 48(3): 456-462.

QIN X, HUANG J, ZHA X, et al. Radar emitter signal recognition based on dilated residual network[J]. Acta Electronica Sinica, 2020, 48(3): 456-462. (in Chinese)

[6] 张敏, 罗正华, 黄建刚, 等. 一种基于I/Q失配的辐射源指纹提取方法[J]. 电子学报, 2020, 48(4): 717-722.

ZHANG M, LUO Z H, HUANG J G, et al. A fingerprint extraction method based on I/Q imbalance[J]. Acta Electronica Sinica, 2020, 48(4): 717-722. (in Chinese)

[7] 许丹, 柳征, 姜文利, 等. 窄带信号中的放大器“指纹”特征提取: 原理分析及FM广播实测实验[J]. 电子学报, 2008, 36(5): 927-932.

XU D, LIU Z, JIANG W L, et al. Extraction of amplifier fingerprints from narrow band signal: Principle analysis and FM broadcast experiment[J]. Acta Electronica Sinica, 2008, 36(5): 927-932. (in Chinese)

[8] 常杰. 基于放大器行为建模的辐射源个体识别方法[D]. 哈尔滨: 哈尔滨工程大学, 2020.

CHANG J. Specific Emitter Identification Method Based on Amplifier Behavior Modeling[D]. Harbin: Harbin Engineering University, 2020. (in Chinese)

[9] 张晓博. 基于深度置信网络的通信辐射源个体识别[D]. 西安: 西安理工大学, 2019.

ZHANG X B. Personal Identification of Communication Radiation Source Based on Deep Belief Network[D]. Xi'an: Xi'an University of Technology, 2019. (in Chinese)

- [10] KIM Y H, DO JO G, OH J H, et al. An efficient simplified behavioral model for RF power amplifiers[C]//2011 IEEE Topical Conference on Power Amplifiers for Wireless and Radio Applications. Piscataway: IEEE, 2011: 65-68.
- [11] MURUGANATHAN S D, SESAY A B. A QRD-RLS-based predistortion scheme for high-power amplifier linearization[J]. IEEE Transactions on Circuits and Systems II: Express Briefs, 2006, 53(10): 1108-1112.
- [12] 云涛. 变步长 LMS 算法及在数字预失真中的应用[J]. 通信技术, 2018, 51(11): 2753-2757.
- YUN T. Variable step-size LMS algorithm and its application in digital pre-distortion[J]. Communications Technology, 2018, 51(11): 2753-2757. (in Chinese)
- [13] 张嘉磊. 基于记忆多项式功放模型的数字预失真算法研究与实现[D]. 成都: 电子科技大学, 2020.
- ZHANG J L. Research and Implementation of Digital Predistortion Algorithm Based on Memory Polynomial Power Amplifier Model[D]. Chengdu: University of Electronic Science and Technology of China, 2020. (in Chinese)
- [14] 蔡天赋, 李明玉, 靳一, 等. 基于 Landweber 迭代算法的欠采样恢复数字预失真技术[J]. 电子与信息学报, 2021, 43(11): 3166-3173.
- CAI T F, LI M Y, JIN Y, et al. An under-sampling restoration digital predistortion technique based on landweber iteration algorithm[J]. Journal of Electronics & Information Technology, 2021, 43(11): 3166-3173. (in Chinese)
- [15] 李明辉, 马洪, 韦玮. 多载波航天测控雷达发射机功放的线性化[J]. 雷达科学与技术, 2007, 5(3): 228-231.
- LI M H, MA H, WEI W. Linearization of power amplifier in multi-carrier radar transmitter for space instrumentation and command network[J]. Radar Science and Technology, 2007, 5(3): 228-231. (in Chinese)
- [16] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-CAM: Visual explanations from deep networks via gradient-based localization[C]//2017 IEEE International Conference on Computer Vision (ICCV). Piscataway: IEEE, 2017: 618-626.
- [17] RAVANELLI M, BENGIO Y. Speaker recognition from raw waveform with SincNet[C]//2018 IEEE Spoken Language Technology Workshop (SLT). Piscataway: IEEE, 2019: 1021-1028.


## 作者简介



赵雅琴 女, 1976 年生, 黑龙江兰西人. 博士. 哈尔滨工业大学教授. 主要研究方向为辐射源识别、辐射源个体识别、无源定位、光通信、医学信号处理. 中国电子学会会员编号: E190012844S.  
E-mail: yaqinzhao@hit.edu.cn



谢丹 女, 1996 年生, 重庆梁平人. 哈尔滨工业大学博士研究生. 主要研究方向为辐射源个体识别.  
E-mail: xiedan\_96@outlook.com



吴龙文(通讯作者) 男, 1988 年生, 江西樟树人. 博士. 哈尔滨工业大学工程师. 主要研究方向为辐射源识别、辐射源个体识别、无源定位. 中国电子学会会员编号: E190036434M.  
E-mail: wulongwen@hit.edu.cn



丁沁宇 男, 1999 年生, 浙江嘉兴人. 哈尔滨工业大学硕士研究生. 主要研究方向为辐射源个体识别、无源定位.  
E-mail: dingqinyu2022@163.com



韩易伸 男, 1997 年生, 辽宁铁岭人. 中国空间技术研究院北京空间飞行器总体设计部工程师. 主要研究方向为辐射源个体识别.  
E-mail: hityishen@163.com



张拯华 男, 1998 年生, 山西太原人. 中国电子科技集团公司第十四研究所工程师. 主要研究方向为辐射源个体识别.  
E-mail: zhang.zh.work@foxmail.com