



·电磁频谱作战与电磁安全·

## 基于压缩残差网络的雷达辐射源识别方法研究\*

郭恩泽<sup>1</sup>, 刘正堂<sup>1</sup>, 崔博<sup>1</sup>, 刘国彬<sup>1</sup>, 史航宇<sup>2</sup>, 蒋旭<sup>1</sup>

(1. 中国人民解放军 63893 部队, 河南 洛阳 471003; 2. 中国人民解放军 63896 部队, 河南 洛阳 471003)

**摘要:** 针对低信噪比条件下, 现有的雷达辐射源信号识别方法存在识别正确率低、时效性差的问题, 提出了一种基于压缩残差网络的雷达辐射源信号识别方法。首先, 利用 Choi-Williams 分布的时频分析方法将时域信号转换为二维时频图像; 然后, 根据应用场景特点, 选择卷积神经网络 (Convolutional Neural Networks, CNN) “压缩”范围; 最后, 构建压缩残差网络来自动提取图像特征并完成分类。仿真实验结果表明, 在同等体量的设计下, 与当前较为常用的标准 CNN 以及 ResNet 模型相比, 所提模型能够降低信号识别运行时间约 88%, 在信噪比为 -14 dB 条件下对 14 种雷达辐射源信号的平均识别率高约 5%。提供了一种高效的雷达辐射源信号智能识别方法, 具有潜在的工程应用前景。

**关键词:** 压缩残差网络; 时频分析; 雷达辐射源识别; 深度学习; 扩张卷积

中图分类号: TN971

文献标志码: A

doi: 10.11884/HPLPB202436.230119

## Radar radiation source recognition method based on compressed residual network

Guo Enze<sup>1</sup>, Liu Zhengtang<sup>1</sup>, Cui Bo<sup>1</sup>, Liu Guobin<sup>1</sup>, Shi Hangyu<sup>2</sup>, Jiang Xu<sup>1</sup>

(1. Unit 63893 of the PLA, Luoyang 471003, China;

2. Unit 63896 of the PLA, Luoyang 471003, China)

**Abstract:** Aiming at the problems of low recognition accuracy and poor timeliness of existing radar emitter signal recognition methods under the condition of low SNR, this paper proposes a radar emitter signal recognition method based on compressed residual network. Using Choi-Williams distribution for reference, the time-domain signal is converted into a two-dimensional time-frequency image, which improves the effectiveness of signal essential feature extraction. According to the characteristics of the application scenario, it selects the “compression” range of convolutional neural networks (CNN), and builds a compression residual network to automatically extract image features and identify. The simulation results show that compared with other advanced models, the proposed method can reduce the running time of signal recognition by about 88%, and the average recognition rate of 14 radar emitter signals is at least 5% higher when the signal-to-noise ratio is -14 dB. This paper provides an efficient intelligent recognition method of radar emitter signal, which has potential engineering application prospects.

**Key words:** compressed residual network, time-frequency analysis, radar radiation source recognition, deep learning, dilated convolution

雷达辐射源信号识别是雷达电子战系统中的关键技术<sup>[1]</sup>。当前, 新体制雷达层出不穷, 雷达信号波形复杂且多变。雷达辐射源信号识别面临以下挑战: 信号形式复杂、信号密度激增、信噪比变化范围较大。这对雷达辐射源信号识别系统的智能化、自动化、准确性和时效性提出了更高的要求<sup>[2]</sup>。雷达辐射源信号识别技术越来越引发学术界和产业界的重视。

基于脉冲描述字的识别方法是早期最常用的方法之一, 主要收集射频 (RF)、脉冲幅度 (PA)、到达时间 (TOA)、到达方向 (DOA) 和脉冲宽度 (PW) 等参数信息, 然后比较不同脉冲描述字之间的差异性, 从而实现对不同

\* 收稿日期: 2023-05-06; 修订日期: 2023-10-20

基金项目: 国家自然科学基金项目 (61571043)

联系方式: 郭恩泽, g1903632257@163.com。

通信作者: 蒋旭, 13525965959@139.com。

类型的雷达信号识别和分类。当电磁环境中的信号密度较低,并且大多数雷达都是常规系统时,使用脉冲间特征进行分类是可行的。然而,现代雷达系统使用了更复杂的信号波形,因此仅凭借脉冲间特征不足以实现信号分类<sup>[1]</sup>。为了识别复杂的雷达信号,需要探索脉冲内部的详细结构,称为脉内特征。这是因为雷达为了拥有更好的探测距离、更高的分辨率等性能,需要对脉内信号进行有意调制,因此,在每个脉冲内都有自己的电信号结构。各国学者设计不同的算法探索雷达辐射源信号的脉内识别问题,随着机器学习方法的引入,雷达辐射源信号识别逐渐朝着智能化的方向发展。根据是否通过人工设计算法来提取雷达信号脉内特征,可将现有方法分为两大类:一是基于传统机器学习的识别方法,二是基于深度学习的识别方法。

基于传统机器学习的识别方法一般分为两步:第一步利用人工方法提取特征;第二步利用传统机器学习方法构建分类器进行识别。文献[4]利用图像处理的相关算法提取时频图像的结构特征,然后利用多层感知机(MLP)进行分类;文献[5]提取主脊切片包络的特征,然后利用聚类分析算法进行分类,文献[6]提出了一种基于时频原子特征的方法,然后利用聚类分析算法进行雷达信号分类。这种基于机器学习的方法在应用中往往存在以下几点问题:(1)人工设计的特征提取算法的好坏通常依赖于从业者的专业领域知识和经验水平,提取的特征往往针对性较强,一旦数据集发生变化,原先的特征提取算法性能会大大下降,使得方法的可迁移性较差;(2)提取的特征往往为“浅层特征”,无法提取更为抽象的“高级”特征,而且特征的好坏无法事先确定,只能通过大量实验去尝试;(3)对噪声表现出很强的敏感性,在低信噪比条件下,通常很难再提取到有效特征,难以满足当下的需求。

近年来,深度学习算法(如SAE、CNN和DBN等)在图像分类<sup>[7]</sup>、语音识别<sup>[8]</sup>、目标探测<sup>[9]</sup>等应用领域取得了突破性的进展,学者开始利用深度学习算法来解决雷达辐射源信号识别问题。深度学习算法的主要思想是利用时频分析方法将雷达原始信号转换成雷达时频图像,此时信号识别问题转化为图像识别问题。深度学习方法是特征提取与识别一体化,其中特征提取是通过构建损失函数<sup>[10]</sup>,利用梯度下降法<sup>[11]</sup>和误差反向传播算法<sup>[12]</sup>从数据中提取判决性表征进而完成对目标的分类。深度学习是一种较为通用、自动、更为智能的方法,通过多层非线性模块的组合能够自动学习到数据集中“好”的、“高级”的特征,而且在不断卷积过程中放大了输入中对于目标分类有利的特征,同时抑制无关的噪声。因此,基于深度学习的方法具有很强的噪声抑制能力和特征学习能力,其应用大大提升了雷达辐射源信号的识别效果。尤其近年来出现具有良好泛化性能的开源模型(如AlexNet<sup>[13]</sup>、VGGNet<sup>[14]</sup>和ResNet<sup>[15]</sup>等),将开源模型应用到雷达辐射源信号识别中是研究趋势。文献[16-18]利用简单的5层CNN神经网络模型实现对8~14种雷达信号的有效识别;文献[19-21]分别利用AlexNet、GoogLeNet、ResNet50等模型完成了多类雷达辐射源信号识别,对雷达信号的识别更高、鲁棒性好;文献[22]提出基于扩张残差网络(DRN)的雷达信号识别方法,并且采用深度为12层的DRN模型,实现了较高的识别效果。

上述识别方法从不同的角度进行了探索,其主要的研究不足在于:雷达时频图像数据集与通用图像数据集在特征方面存在着较大的差别,因此,将开源模型直接应用到雷达信号识别中存在严重的外推误差,主要表现在低信噪比条件下识别率较低以及难以识别易混淆信号。本文在对比分析雷达信号时频图像和常规图像特征特点的基础上,提出一种适用于雷达时频图像识别的改进CNN模型,即压缩残差网络(CRN)。在噪声能量较高的情况下,本文CRN模型有着更强的特征提取能力,提高了低信噪比条件下的雷达辐射源信号的识别率。

## 1 雷达辐射源信号预处理

雷达信号是非平稳信号,时频分析能够反映信号能量随时间和频率的变化关系。Choi-Williams分布是雷达信号时频分析普遍运用的方法,其能够保持高时频分辨率的同时有效地抑制交叉项,能较多地保留信号的真实特征。与文献[3, 16-19, 22]类似,本文采用CWD操作进行雷达辐射源信号时频变换,具体为

$$F_{\text{CWD}}(t, \omega) = \iint \frac{1}{\sqrt{4\pi\tau^2/\sigma}} \exp\left[-\frac{(t-u)^2}{4\tau^2/\sigma}\right] s\left(t + \frac{\tau}{2}\right) s^*\left(t - \frac{\tau}{2}\right) \exp(-j\omega\tau) du d\tau \quad (1)$$

式中: $t$ 和 $\omega$ 表示时间和角频率; $\sigma$ 为衰减系数,为了兼顾高时频分辨率和抑制交叉项, $\sigma$ 取1。

图1表示在信噪比为0 dB条件下14类雷达辐射源信号的CWD时频分布图。由图可见,信号结构特征存在一定程度的破坏,部分信号细微特征被淹没在“噪声”能量中。其中,常规脉冲信号(CW)、线性调频信号(LFM)、二相编码信号(BPSK)、二相频率编码信号(BFSK)、跳频信号(COSTAS)时频能量分布较为集中,特征较为突出,与其他信号差异明显。此外,由巴克码控制的相位编码信号(BPSK)和四相编码信号(QPSK)结构有些类似,但是它们的特征还不够明显。最后,多相编码信号(如FRANK、P1、P2、P3、P4)设置相同的步进频率,P1、P2与P4、

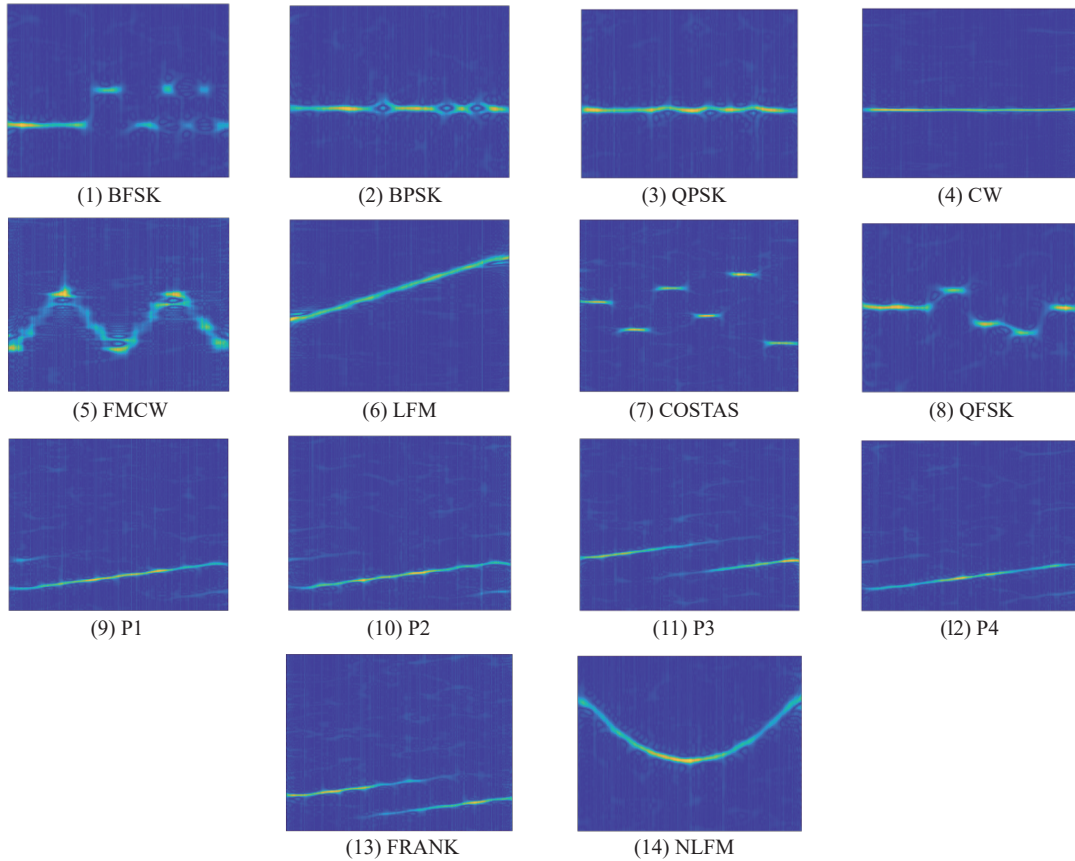


Fig. 1 CWD time-frequency distribution of 14 radar emitter signals

图 1 14类雷达辐射源信号的CWD时频分布图

FRANK 与 P3 这五种多相编码信号之间的区别难以分辨, 而且在较低信噪比下容易混淆。因此, 设计泛化性能高的网络模型, 实现对雷达辐射源信号的有效识别是亟待解决的问题。

文献 [17, 22] 在信号预处理过程中, 仅对图像进行灰度化处理, 保留各信噪比条件下时频图像的完整信息。对原始图像作过多的预处理(如滤波、降噪等)在一定程度上可以提高信噪比, 但是会破坏时频图像的细微特征, 进而影响对雷达辐射源信号的有效识别。例如, FRANK 与 P1 会出现“阶梯”特征, P2 与 P4 信号时频图两端的微弱能量值, BPSK 与 QPSK 的侧面微弱能量值。预处理过程如图 2 所示, 不对时频图像进行降噪、滤波等过多预处理, 仅对图像进行灰度化处理, 然后利用双三次插值将时频图像的尺寸调整为  $224 \times 224$ , 以减少输入尺寸过大导致额外计算开销。




Fig. 2 Signal preprocessing flow chart

图 2 信号预处理流程图

## 2 基于压缩残差网络的雷达辐射源信号识别

### 2.1 残差网络

理论上复杂的深度网络模型有助于提取图像更为抽象的高级特征, 发现特征之间的深层联系。随着网络深度的逐渐加深, 容易导致网络模型难以优化, 泛化性能逐渐退化的问题。针对这一难点, 文献 [15] 构建快捷连接的残差网络模型 ResNet, 具体的网络结构模型如图 3 所示。其中  $X$  表示卷积神经网络某一层输入, 输入到输出的快捷连接等于恒等映射,  $H(X)$  表示期望映射输出,  $F(X)$  表示残差映射, 即  $F(X) = H(X) - X$ 。

### 2.2 扩张残差网络 (DRN)

残差网络使用池化和下采样获取更抽象的特征, 直到最后一层卷积输出一个保留很少空间信息的特征图(通

常尺寸为7×7),通过全局平均池化输入 softmax 分类器,最后计算类别概率来分类图像。文献 [23] 通过实验分析认为,空间分辨率的损失难以适应分类任务,高分辨率的特征图更容易提取目标完整的信息。这同样降低了卷积核的感受野,难以实现分辨率和感受野的权衡。此时,扩张残差卷积用于补偿分辨率增加后的感受野降低。

卷积核扩张的大小由扩张因子决定,经过扩张后的卷积核大小可表示为

$$k_c = dk_{size} \quad (2)$$

式中:  $k_c$  表示扩张后的卷积核大小;  $k_{size}$  表示扩张前卷积核大小;  $d$  表示扩张因子。

如图 4 所示,红点代表有价值权重,扩张部分卷积核权重值为 0,图 4 分别表示扩张因子  $d$  设置为 1、2、4 以及卷积核大小分别设置为 3×3、5×5、9×9 条件下卷积层的运算输出。




Fig. 4 Expansion convolution and receptive field

图 4 扩张卷积与感受野

在卷积神经网络中,感受野为卷积神经网络每一层输出特征图上的像素点在上层特征图上的映射区域大小,通过多层迭代可以计算各层特征图上的像素点对应的上层特征图映射区域。感受野可以表示为

$$R(n-1) = [R(n) - 1]s + k_{size} \quad (3)$$

式中:  $R(n)$  表示第  $n$  层卷积层的感受野;  $R(n-1)$  表示  $R(n)$  在第  $n-1$  层的感受野;  $s$  和  $k_{size}$  表示第  $n-1$  层卷积运算步长和卷积核大小。

图 4 中绿色阴影区域表示在  $k_{size}=3, s=1$  时,第  $n$  层的一个像素点对应  $n-1, n-2, n-3$  层的感受野。由式(4)可知,当未采用扩张卷积时,即  $d=1$  时,  $n-1, n-2, n-3$  层的感受野分别为 3×3、5×5、7×7,当  $d$  为 2、4,  $n-2, n-3$  层的感受野增大至 7×7、15×15。

文献 [22] 设计了适用于雷达辐射源信号识别的 DRN 模型。该模型以残差网络为主体结构,省略了 ResNet 中 conv4\_1 与 conv5\_1 层下采样,输出特征图尺寸分别由原来的 14×14、7×7 变为 28×28,其中 conv4\_x、conv5\_x 部分的卷积扩张因子  $d$  设置为 2 和 4。

### 2.3 压缩残差网络的提出与设计

DRN 在底层有着较高的分辨率,并且扩张卷积拥有更大的感受野,便于提取到辐射源信号的细微特征。因此,DRN 对于信噪比较高的雷达时频图像<sup>[22]</sup>和拥有丰富特征信息的通用图像数据<sup>[23]</sup>有着较好的识别率。对于信噪比相对较低的雷达信号,DRN 存在识别存在特征提取困难、识别正确率低的问题。这是由于 CNN 架构本身的模块设计所导致,卷积神经网络在经过一系列卷积运算之后最后会进行全局平均池化(GAP)<sup>[24]</sup>,可以有效缓解模型训练中的过拟合问题,从而提升模型的性能<sup>[25]</sup>。GAP 的数学表达如下

$$f = \sum_{i=1}^N \sum_{j=1}^M x_{ij} \quad (4)$$




Fig. 3 Basic structure of residual unit

图 3 残差单元基本结构



式中:  $f$  为 GAP 运算之后输出值;  $M$ 、 $N$  为特征图尺寸;  $x_{ij}$  为特征图像素值。

对于常规图像而言, 图像质量一般较好, 常规图像数据集往往有着丰富的类别特征信息和较多的细微信息。DRN 模型分辨率较高, 最后输出特征图中有更多特征信息<sup>[26]</sup>, 经过 GAP 运算之后更有助于分类。因此, DRN 针对常规图像的识别效果比同等体量的 ResNet 和普通 CNN 网络要好。但是, 对于雷达信号而言, 雷达时频图像相对来说特征信息较少, 而且获取雷达辐射源信号的环境往往是复杂的, 是充斥大量噪声的电磁场环境, 所以信号信噪比较低, 图像质量相对较差。因此, DRN 模型的输出特征图中增加的有用特征较为有限, 但是能量较强的噪声信息将大量增加, 过 GAP 运算之后, 信号特征信息更有可能被随机噪声信息所“覆盖”, 从而导致模型分类困难。

上述问题, 在这些原本应用于常规图像识别的开源模型中不同程度地存在。基于此, 我们设计了不同于上述开源模型的压缩模型, 通过压缩输出特征图分辨率的方法增强模型抑制噪声的能力, 压缩输出特征图分辨率会在一定程度上削弱 CRN 模型提取更多特征的能力, 同样也会削减输出特征图中的噪声信息, 而且降低了特征图中的信息“维数”, 使得模型更高效准确地提取目标表征信息。因此, 最后用于分类的输出特征图中有效的特征信息减少有限, 噪声信息大量减少, 经过 GAP 运算之后, 图像的特征信息更为明显, 不容易被噪声“覆盖”, 有助于 CRN 模型分类识别。

同文献<sup>[22]</sup>的设计思路一致, 本文以文献<sup>[15]</sup>提出的残差网络为主体结构, 图 5 为本文设计的 CRN 模型。ResNet 由 input、conv1, maxpool, conv2\_x, conv3\_x, conv4\_x, conv5\_x, GAP, fc 组成。为了实现压缩特征图尺寸, CRN 模型在 ResNet 基础上增加了 conv6\_x 卷积结构。为了避免扩张卷积导致的“网格效应”, 所提 CRN 模型未采用扩张卷积, 即扩张系数  $d$  均为 1。根据网络的压缩程度, 本文提出两个 CRN 网络模型, 其中第一个模型未对 conv6\_x 输入特征图进行填充, 直接进行  $3 \times 3$  卷积操作, 卷积步长  $s$  为 1, 最后得到输出特征图尺寸为  $5 \times 5$ ; 第二个模型在第一种操作的基础上将卷积步长  $s$  设置为 2, 得到输出特征图尺寸为  $3 \times 3$ 。输入图像尺寸和通道数均与文献<sup>[22]</sup>相同, 因此卷积核尺寸和通道数设置均与其保持一致。conv2\_x~conv6\_x 均使用一个残差单元, 图中虚线表示当输入与输出特征图尺寸和维度不一致时, 需要采用  $1 \times 1$  卷积核对输入特征图进行相匹配的卷积操作。为了缓解模型训练中出现的梯度弥散和消失问题, 每次卷积运算后均进行批量标准化操作<sup>[27]</sup>, 即增加 BN 层。同时, 本文在 BN 层后的激活层选用 ReLU 作为激活函数<sup>[28]</sup>, 能够实现加速模型收敛, 提升训练进度的效果。




Fig. 5 CRN model

图 5 CRN 模型

### 3 仿真结果与分析

仿真实验包括两个部分, 首先测试 CRN 与 DRN 设计方法对 14 类雷达辐射源信号的识别性能, 其次将 CRN 模型与当前图像识别领域表现良好的 CNN 模型、ResNet 模型进行识别性能对比。

#### 3.1 实验环境和参数设置

本实验在配置为 Intel Core-i7 2.8 GHz, 8 G 内存的 Windows 系统 PC 机上运行。本文对 14 种雷达辐射源信号进行分类识别, 仿真信号脉宽设置为  $2 \mu\text{s}$ , 采样频率  $f_s$  设置为 400 MHz, 不同信号的参数设置如表 1 所示。信噪比范围为  $[-16 \text{ dB}, 0 \text{ dB}]$ , 步长 2 dB, 每个信噪比下各类信号均生成 600 个脉内调制信号, 利用 CWD 时频分析处理和数据预处理生成数据集。训练集、验证集和测试集比例为 4:1:1。利用训练集和验证集进行模型的离散训练, 待训练完毕后将训练好的模型对测试集 14 种辐射源信号进行识别测试。

表 1 信号参数设置

Table 1 Signal parameter setting

modulation type	parameter	ranges
CW	carrier frequency $f_0$	$[1/10, 1/4]f_s$
LFM、NLFM	carrier frequency $f_0$	$[1/10, 1/4]f_s$
	bandwidth $B$	$[1/10, 1/4]f_s$
BPSK	carrier frequency $f_0$	$[1/10, 1/4]f_s$
	barker code length	7
QPSK	carrier frequency $f_0$	$[1/10, 1/4]f_s$
	phase coding sequence length	6
FMCW	carrier frequency $f_0$	$[1/20, 1/5]f_s$
	bandwidth $B$	$[1/20, 1/5]f_s$
	cycle $T$	1 $\mu$ s
FRANK、P1、P2、P3、P4	carrier frequency $f_0$	$[1/10, 1/4]f_s$
	step frequency $N$	{6, 8}
BFSK	carrier frequency $f_0$	$[1/20, 1/4]f_s$
	barker code length	{11, 13}
QFSK	carrier frequency $f_0$	$[1/10, 1/4]f_s$
	frequency coding sequence length	{6, 7}
COSTAS	carrier frequency $f_0$	$[1/10, 1/4]f_s$
	frequency coding sequence length	{6, 7, 8}

### 3.2 不同方法识别性能对比

为了验证所提 CRN 模型设计方法的识别率、时效性, 本文将其和文献 [22] 提出的 DRN 模型设计方法进行对比。本文所设计的方法根据卷积层输出特征图尺寸分别记为本文模型 1 和模型 2。需要注意的是, 本文利用文献 [22] 方法设计同等体量的 DRN 模型, 在 DRN 模型基础上增加 conv6\_x 卷积结构, 该结构 conv6\_1 卷积部分不进行下采样操作, 特征图尺寸保持不变。与 conv5\_x 类似, 卷积核扩张因子  $d=4$ 。

#### 3.2.1 识别率对比

图 6 为三种模型对 14 种信号的识别率变化曲线。由图可见, 三种模型性能较为稳定, 随着信噪比的提高, 对信号的识别率在稳定上升。具体地, 本文设计的两个 CRN 模型识别率较为接近, 在各信噪比条件下均高于文献 [22] 设计的 DRN 模型, 本文所提 CRN 模型平均识别率分别为 93.01%、93.03%, 文献 [22] 模型仅为 84.08%。分析其原因在于本文 CRN 模型通过压缩特征图尺寸, 降低了特征图中噪声能量的影响, 更容易提取信号的判决性表征信息, 模型性能较好, 因此对各类辐射源信号识别率较高。文献 [22] DRN 模型增加了特征图尺寸, 有助于提取更多的特征信息, 但是雷达时频图特征信息相对较少, 能够增加的特征信息有限, 而且由于信噪比较低, 噪声信息的能量有所加强, 覆盖了有用信号的特征信息, 因此模型性能下降, 对各类信号的识别率较低。

多相编码信号特征相似, 通过图 1 可以看出, P1 和 P2 均由一条步进的斜线组成, 而且“阶梯”形状类似, 通过肉眼难以分辨。FRANK 和 P3 都是由两条平行线构成, 不同的是 FRANK 有一定的“阶梯”形状。此外, P4 码由一条平行线构成, 与 P1 和 P2 类似。上述信号在低信噪比条件下极易混淆, 接下来测试深度模型对易混淆信号的识别性能。图 7 为不同方法对多相编码信号的识别率。

由图 7 可知, 本文所提方法识别率接近, 且较为稳定, 并且随着信噪比的增加, 识别率在稳步上升。文献 [22] 方法对 FRANK、P1、P3 识别较为稳定, 但是在各信噪比条件下识别率均低于本文所提方法。具体地, 对 P4 信号识

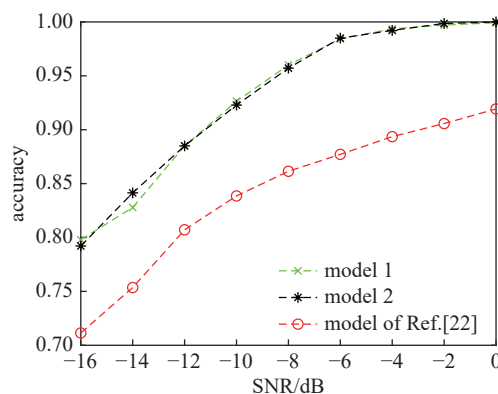


Fig. 6 Comparison of recognition rates of different design methods

图 6 不同设计方法识别率对比

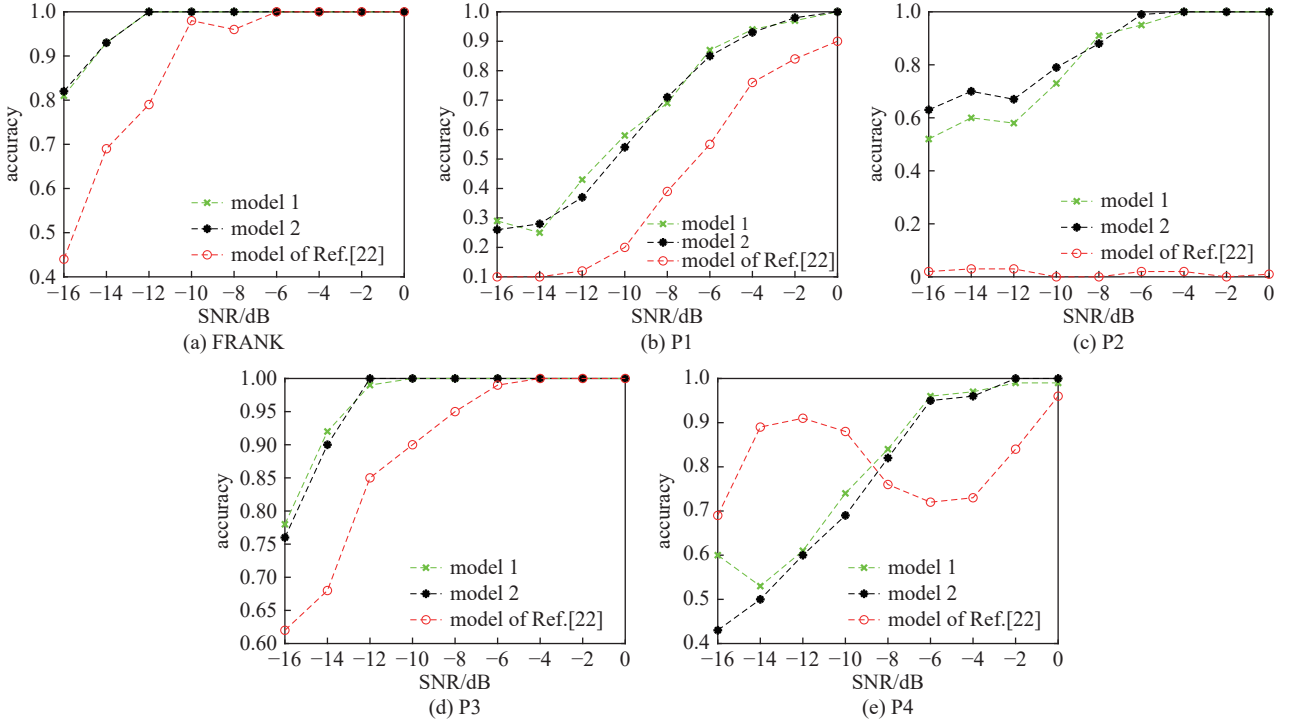


Fig. 7 Recognition rate of polyphase coded signals by different methods

图 7 不同方法对多相编码信号的识别率

别不稳定,随着信噪比提高,识别率呈波动变化,而且对 P2 信号几乎无法识别。本文方法在对易混淆信号的识别率和识别稳定性方面均优于文献 [22] 方法,主要原因在于文献 [22] 方法特征图中噪声信息增加过多,进而覆盖了模型的特征信息。而本文方法降低了随机噪声的影响,更容易提取到目标的判决性表征信息,因此对易混淆信号识别更精确。

图 8 给出了在信噪比为 -14 dB 时不同方法识别多相编码的混淆矩阵。具体地,各对比模型方法均对多相编码信号产生不同程度的混淆,尤其是 P1、P2 和 P4 码,这是因为其特征较为相似,极易产生混淆。P1、P2 和 P4 码差别主要在于步进频率产生的能量相对微弱的“阶梯”形状。文献 [22] 方法由于扩大特征尺寸,低信噪比条件下会引入大量的噪声能量,使得用于分类的特征图信息被随机噪声覆盖。综上,文献 [22] 方法在低信噪比条件下难以识别 P1 和 P2 信号,并且将其误识别为 P4 信号。本文方法通过压缩最后用于分类的特征图尺寸,减少了随机噪声的能量,使模型能提取到有效的特征图信息,能对 P1 和 P2 信号进行较好地识别。

### 3.2.2 时效性对比

时效性衡量指标表示完成一次识别所需要的时间,主要与进行一次识别所需要的乘加计算量有关<sup>[29-30]</sup>。深度模型的复杂度主要由网络规模和模型参数量组成,其中参数量主要由卷积层和全连接层的参数量决定。基于本文方法设计的 CRN 模型和基于文献 [22] 方法设计的 DRN 模型具有相同的参数量,其卷积运算需要乘加计算量 (FLOPS)  $S$  可以表示为

$$S = D_{in}D_{in}MND_{out}D_{out} \quad (5)$$

式中:  $D_{in}$  为特征图输入尺寸;  $D_{out}$  为特征图输出尺寸;  $M$ 、 $N$  分别为输入、输出特征通道数。

表 2 给出了不同模型各层卷积运算需要的乘加计算量。为了不失一般性,本文忽略用于升维的逐点卷积计算量。由表 2 可知,本文所提两个 CRN 模型需要的乘加计算量仅在 conv6\_x 层不同,由于两个模型的计算量接近,此处仅分析模型 1 的计算量。CRN 与 DRN 两种模型 conv1~conv3\_x 结构相同,因此乘加计算量相同。conv4\_x~conv6\_x 输入和输出通道数较高,DRN 模型由于扩张了特征图尺寸,底层卷积部分的计算量会成倍增加。然而 CRN 模型未扩张特征图尺寸,在最后一层进行尺寸压缩,进一步减少了信号识别的乘加计算量。具体地,文献 [22] 方法进行一次图像识别需要的乘加计算次数 1 912 M,本文 CRN 模型约为 218 M,仅为 DRN 模型 11.4%,CRN 模型时效性远高于 DRN 模型。利用上述不同模型对 20000 张雷达时频图像进行识别,DRN 模型进行一次识别的平均时间为 1.77 ms,而 CRN 模型仅为 0.21 ms,CRN 模型识别时效性大约是 DRN 模型的 8.4 倍。CRN 模型和 DRN 模型

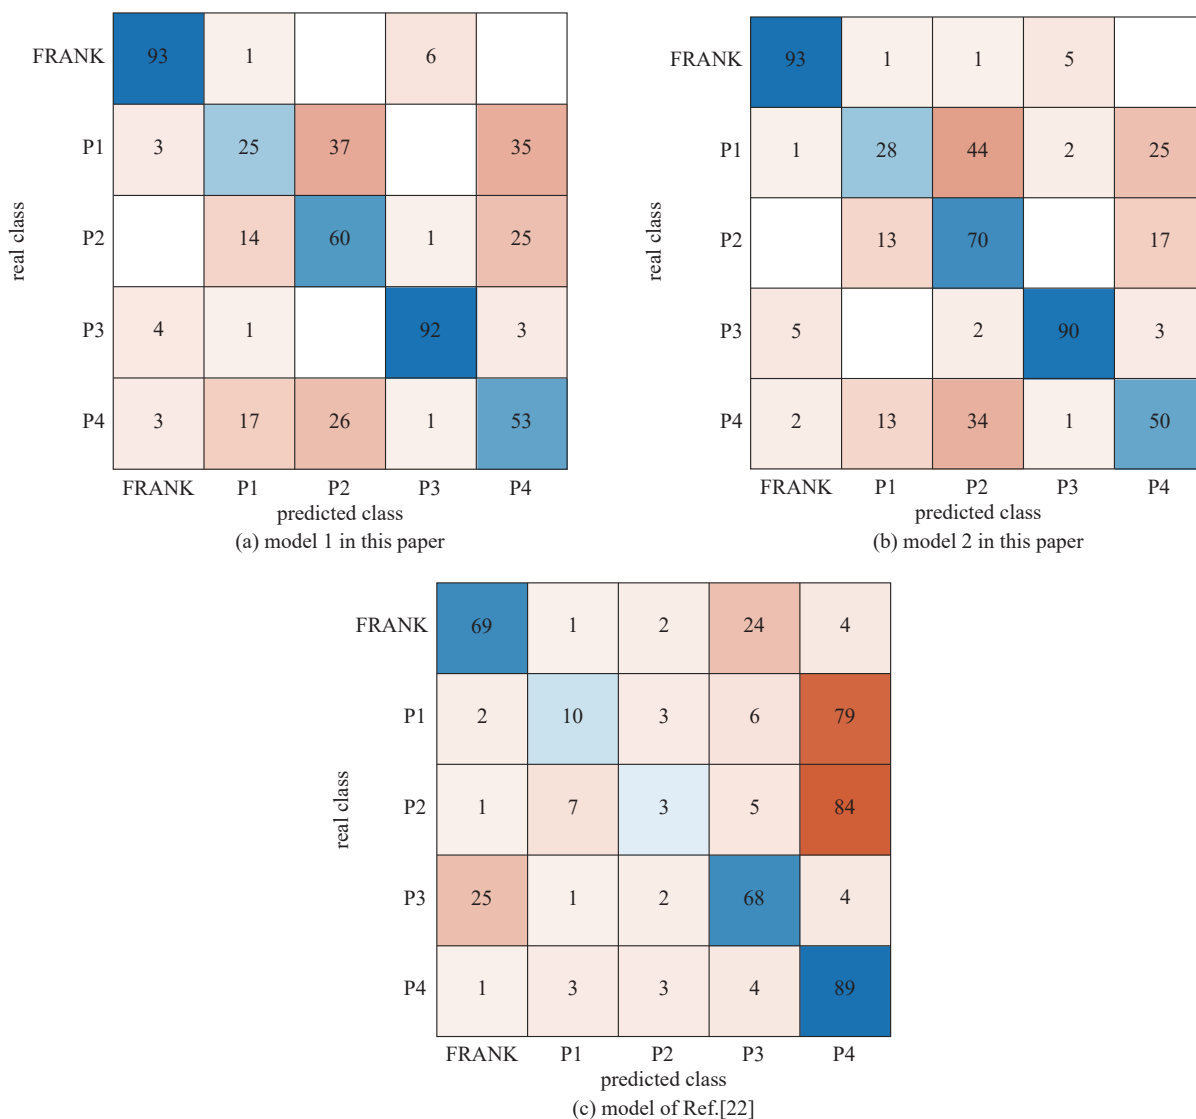


Fig. 8 Confusion matrix for different methods to identify polyphase coding

图 8 不同方法识别多相编码信号的混淆矩阵

表 2 不同模型各卷积运算需要的乘加计算量

Table 2 Multi-adds calculation amount required for each convolution operation of different models

model structure	FLOPS			
	model 2 of this article		Ref. [22] model	
conv1	112×112×1×32×7×7	19668992	112×112×1×32×7×7	19668992
conv2_x	56×56×32×32×3×3×2	57802752	56×56×32×32×3×3×2	57802752
conv3_x	28×28×32×64×3×3+28×28×64×64×3×3	43352064	28×28×32×64×3×3+28×28×64×64×3×3	43352064
conv4_x	14×14×64×128×3×3+14×14×128×128×3×3	43352064	28×28×64×128×3×3+28×28×128×128×3×3	173408256
conv5_x	7×7×128×256×3×3+7×7×256×256×3×3	43352064	28×28×128×256×3×3+28×28×256×256×3×3	693633024
conv6_x	3×3×256×256×3×3×2	10616832	28×28×256×256×3×3×2	924844032
fc	256×14	3584	256×14	3584
sum		218, 148, 352		1, 912, 712, 704

的具体运行时间与理论分析相一致。

### 3.3 其他模型对比

为了进一步验证 CRN 模型在低信噪比条件下的识别性能,本节 CRN 模型与当前在图像识别领域表现良好的标准 CNN 模型<sup>[16-18]</sup>和 ResNet 模型<sup>[9,21]</sup>进行对比。需要注意的是,本节选取输出特征图尺寸为 3×3 的 CRN 模型。



三种测试模型设置为同等体量, 具有相同的卷积层、池化层、批量标准化层, 其中 CRN 模型在 conv6\_1 使用卷积步长  $s$  设置为 2 的下采样, CNN 模型与 ResNet 模型在 conv6\_1 不进行下采样, CRN 模型与 ResNet 模型在 CNN 模型的基础上增加了捷径连接。

图 9 给出各模型在信噪比设置为  $-16\text{ dB}\sim 0\text{ dB}$  时的信号识别率。由图 9 可知, 三种模型对 14 种雷达辐射源信号的识别较为稳定, 随着信噪比的提高, 识别率在稳步上升。总体来说, 在不同信噪比条件下 CRN 表现最优, 其次是 ResNet 模型、CNN 模型的识别率最差, 特别是信噪比越低, CRN 模型的优越性越明显。分析其原因是 CRN 模型利用尺寸压缩降低了随机噪声的能量信息, 更容易提取信号的特征信息, 使最后用于分类的特征图有效信息更加明显, 从而在低信噪比条件下得到更高的识别性能。

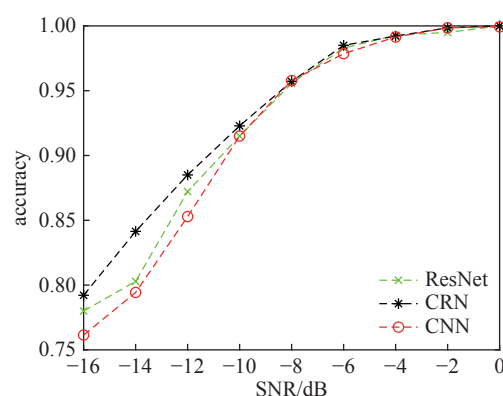


Fig. 9 Overall recognition rate of each model

图 9 各模型整体识别率

## 4 结论

本文提出基于压缩残差网络的雷达辐射源信号识别模型, 解决了低信噪比条件下复杂多类雷达辐射源信号识别正确率低、时效性差的问题。首先利用 CWD 时频分析方法将信号识别问题转化为图像识别问题, 其次, 借鉴全局平均、池化特征图的思想, 分析不同应用场景下“扩张”可行性, 提出压缩残差网络设计方法, 有效提高了特征学习表征能力。实验表明, 与当前较为先进的 DRN、ResNet、CNN 模型相比, 本文方法在抗噪性能、识别率以及时效性方面性能更优。

本文的模型设计方法, 具备一定的可推广行。从 CNN 架构和识别机理的角度去分析, 本文的压缩模型表现出了较强的抗噪声性能以及关键特征的提取能力, 因此, 对于细微特征较少, 或者噪声能量较大的目标有很强分类性能。下一步我们将利用更多的数据集去验证本文所提方法的推广范围, 例如通信脉内调制信号数据集、无人机辐射源信号数据集、SAR 图像数据集等。本文提供的模型具有潜在工程应用价值。

## 参考文献:

- [1] López-Risueño G, Grajal J, Sanz-Osorio A. Digital channelized receiver based on time-frequency analysis for signal interception[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2005, 41(3): 879-898.
- [2] Zhang Ming, Diao Ming, Gao Lipeng, et al. Neural networks for radar waveform recognition[J]. *Symmetry*, 2017, 9(5): 75.
- [3] Kishore T R, Rao K D. Automatic intrapulse modulation classification of advanced LPI radar waveforms[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2017, 53(2): 901-914.
- [4] Zilberman E R, Pace P E. Autonomous time-frequency morphological feature extraction algorithm for LPI radar modulation classification[C]//2006 International Conference on Image Processing. 2006: 2321-2324.
- [5] Guo Qiang, Nan Pulong, Zhang Xiaoyu, et al. Recognition of radar emitter signals based on SVD and AF main ridge slice[J]. *Journal of Communications and Networks*, 2015, 17(5): 491-498.
- [6] Zhu Ming, Jin Weidong, Pu Yunwei, et al. Classification of radar emitter signals based on the feature of time-frequency atoms[C]//2007 International Conference on Wavelet Analysis and Pattern Recognition. 2007: 1232-1236.
- [7] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[DB/OL]. arXiv preprint arXiv: 1409.1556, 2015.
- [8] Tompson J, Goroshin R, Jain A, et al. Efficient object localization using convolutional networks[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition. 2015: 648-656.
- [9] Sainath T N, Kingsbury B, Mohamed A R, et al. Improvements to deep convolutional neural networks for LVCSR[C]//2013 IEEE Workshop on Automatic Speech Recognition and Understanding. 2013: 315-320.
- [10] Lecun Y, Bengio Y, Hinton G. Deep learning[J]. *Nature*, 2015, 521(7553): 436-444.
- [11] LeCun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition[J]. *Proceedings of the IEEE*, 1998, 86(11): 2278-2324.
- [12] Rumelhart D E, Hinton G E, Williams R J. Learning representations by back-propagating errors[J]. *Nature*, 1986, 323(6088): 533-536.
- [13] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks[C]//Proceedings of the 25th International Conference on Neural Information Processing Systems. 2012: 1097-1105.
- [14] Szegedy C, Liu Wei, Jia Yangqing, et al. Going deeper with convolutions[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition. 2015: 1-9.
- [15] He Kaiming, Zhang Xiangyu, Ren Shaoqing, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern

- Recognition. 2016: 770-778.
- [16] Zhang Ming, Diao Ming, Guo Limin. Convolutional neural networks for automatic cognitive radio waveform recognition[J]. *IEEE Access*, 2017, 5: 11074-11082.
- [17] Zhang Ming, Liu Luta, Diao Ming. LPI radar waveform recognition based on time-frequency distribution[J]. *Sensors*, 2016, 16(10): 1682.
- [18] Kong S H, Kim M, Hoang L M, et al. Automatic LPI radar waveform recognition using CNN[J]. *IEEE Access*, 2018, 6: 4207-4219.
- [19] Peng Shengliang, Jiang Hanyu, Wang Huaxia, 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.
- [20] Gao Jingpeng, Shen Liangxi, Gao Lipeng. Modulation recognition for radar emitter signals based on convolutional neural network and fusion features[J]. *Transactions on Emerging Telecommunications Technologies*, 2019, 30(12): e3612.
- [21] Kumar Y, Sheoran M, Jajoo G, et al. Automatic modulation classification based on constellation density using deep learning[J]. *IEEE Communications Letters*, 2020, 24(6): 1275-1278.
- [22] 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 Xin, Huang Jie, Zha Xiong, et al. Radar emitter signal recognition based on dilated residual network[J]. *Acta Electronica Sinica*, 2020, 48(3): 456-462)
- [23] Yu F, Koltun V, Funkhouser T. Dilated residual networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition. 2017: 636-644.
- [24] Lin Min, Chen Qiang, Yan Shuicheng. Network in network[DB/OL]. arXiv preprint arXiv: 1312.4400, 2014.
- [25] Dos Santos C F G, Papa J P. Avoiding overfitting: A survey on regularization methods for convolutional neural networks[J]. *ACM Computing Surveys*, 2022, 54: 213.
- [26] Wang Panqu, Chen Pengfei, Yuan Ye, et al. Understanding convolution for semantic segmentation[C]//2018 IEEE Winter Conference on Applications of Computer Vision (WACV). 2018: 1451-1460.
- [27] Ioffe S, Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[C]//Proceedings of the 32nd International Conference on Machine Learning. 2015: 448-456.
- [28] Glorot X, Bordes A, Bengio Y. Deep sparse rectifier neural networks[C]//Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics. 2011: 315-323.
- [29] Zhang Xiangyu, Zhou Xinyu, Lin Mengxiao, et al. ShuffleNet: An extremely efficient convolutional neural network for mobile devices[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2018: 6848-6856.
- [30] Sandler M, Howard A, Zhu Menglong, et al. MobileNetV2: Inverted residuals and linear bottlenecks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2018: 4510-4520.