

# 低信噪比下基于分裂EfficientNet网络的雷达信号调制方式识别

李 钦, 刘 伟, 牛朝阳, 宝音图, 惠周勃  
(中国人民解放军战略支援部队信息工程大学, 河南郑州 450001)

**摘要:** 针对低信噪比条件下复杂多类雷达信号调制方式识别率低的问题, 本文提出了一种基于时频分析和深度学习的雷达信号调制方式识别方法. 利用CTFD(Cohen class Time-Frequency Distribution)时频分析将信号时域波形变换为二维时频图像, 更清晰地表征信号特征; 采用灰度化和双三次插值运算等方法对时频图预处理, 实现图像通道数和尺寸的减少, 以降低深度学习模型数据输入量; 进一步调整输入输出通道数构建小型EfficientNet网络, 再由多个小型网络并行处理构建分裂网络EfficientNet-B0-Split3, 将时频图像输入网络实现雷达信号调制方式识别. 实验结果表明, 在信噪比为-8 dB时, 新方法对17类不同调制方式的雷达信号整体识别率可达97.1%, 相对于扩张残差网络提高约2.4个百分点; 在信噪比为-10 dB时, 识别率可达92.1%, 相对于EfficientNet提高约0.7个百分点, 提升了低信噪比条件下复杂多类雷达信号调制方式识别率.

**关键词:** 雷达信号; 调制识别; 时频分析; 深度学习; 分裂EfficientNet

中图分类号: TN971

文献标识码: A

文章编号: 0372-2112(2023)03-0675-12

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

DOI: 10.12263/DZXB.20210656

## Radar Signal Modulation Recognition Based on Split EfficientNet Under Low Signal-to-Noise Ratio

LI Qin, LIU Wei, NIU Chao-yang, BAO Yin-tu, HUI Zhou-bo  
(PLA Strategic Support Force Information Engineering University, Zhengzhou, Henan 450001, China)

**Abstract:** Aiming at the low recognition rate of complex and multi-class radar signal modulation under the condition of low signal-to-noise ratio (SNR), this paper proposes a radar signal modulation recognition based on time-frequency analysis and deep learning. Using Cohen class time-frequency distribution (CTFD), transform the signal time-domain waveform into a two-dimensional time-frequency image to characterize the signal characteristics more clearly. Using methods such as grayscale and bicubic interpolation, preprocess the time-frequency image to reduce the number and size of image channels and the amount of data input for deep learning models. Further, adjusting the number of input and output channels to build a small EfficientNet. Then multiple small networks are processed in parallel to construct a split network EfficientNet-B0-Split3. The network gets the inputted time-frequency images and realizes the radar signal modulation recognition. The experimental results show that when the SNR is -8 dB, the overall recognition rate of the new method for radar signals with 17 different modulation methods can reach 97.1%, which is about 2.4 percentage points higher than dilated residual network (DRN); when the SNR is -10 dB, the recognition rate can reach 92.1%, which is about 0.7 percentage points higher than EfficientNet, improves the recognition rate of complex and multi-class radar signal modulation methods under the condition of low SNR.

**Key words:** radar signal; modulation recognition; time-frequency analysis; deep learning; split EfficientNet

### 1 引言

雷达信号调制方式识别是实现电子侦察的关键步骤之一. 基于人工决策和模板匹配的传统识别方法, 存在人工提取有效特征参数难、识别信号单一、识别效率

低、在电磁干扰较大的环境下识别效果差等问题, 已经无法满足现代战争的要求. 随着深度学习的发展, 越来越多的研究人员开始使用基于神经网络的信号识别方法来解决传统信号识别方法的不足, 实现复杂多类雷

达信号调制方式识别的智能化。

基于神经网络的方法,一种方式是将信号一维时域波形作为神经网络的输入.文献[1]将长短时记忆网络(Long Short-Term Memory, LSTM)与深度神经网络(Deep Neural Networks, DNN)结合,实现了对单载频信号(Single Carrier Signals, SCS)、二进制频移键控(BFSK)等六种简单信号的识别;文献[2]使用结合注意力机制的一维卷积神经网络(CNN-1D-AM)对七种不同的简单雷达发射信号进行识别,在信噪比为-6 dB时识别率接近95%.由于时频图可以较好地反映信号特征,研究人员更多地选择将信号转换为时频图像作为神经网络的输入.文献[3]将深度学习和集成学习结合,利用小波变换(Wavelet Transform, WT)获取时频图,通过栈式降噪自编码(Stacked Denoising Auto-Encoder, SDAE)提取时频特征,最后由多个支持向量机(Support Vector Machine, SVM)组合的分类器输出识别结果,在信噪比为-5 dB条件下对八种常见雷达信号识别率接近88%.文献[4]通过短时傅立叶变换(Short-Time Fourier Transform, STFT)提取时频特征并进行稀疏域降噪,最后构建栈式稀疏降噪自编码识别网络(Stacked Sparse Denoising Auto-Encoder, SSDAE)对八种常见雷达信号进行识别,虽然识别率较高,但信号种类较少且缺乏随机性.文献[5]将时域、频域以及时频域信号图像作为压缩激励网络(Squeeze-and-Excitation Networks, SE-Net)的输入,在信噪比为-8 dB条件下对七种较易区分的信号识别率可达90%.文献[6]使用Choi-Williams分布(Choi-Williams Distribution, CWD)将七种信号转化为时频图,经过IIF-Net训练后得到较高的识别率,但是网络参数多,计算量大.文献[7]对八种常见雷达信号进行CWD时频变换后使用残差网络进行去噪,最后通过Inception-V4网络在信噪比为-10 dB条件下识别率可达90%以上,但是没有考虑网络复杂度,在系统的快速性上还未可知。

总的来说,将深度学习技术应用在雷达信号识别方面已取得了一定的研究成果,但是仍然存在识别信号种类少,识别信号缺乏随机变化且易于区分,在低信噪比条件下识别效果不理想等问题.针对以上问题,本文提出了基于时频分析和深度学习的雷达信号调制方式识别新方法.该方法首先将包括有SCS、线性调频(Linear Frequency Modulation, LFM)、非线性调频(NLFM)、二相编码(BPSK)、多相编码(Frank、P1~P4和T1~T4)、频率编码(Costas)以及复合调制(频率编码与LFM复合调制FSK+LFM、频率编码与BPSK复合调制FSK+BPSK、LFM与BPSK复合调制LFM+BPSK)共17种不同调制方式的雷达信号,通过CTFD时频分析方法转换为时频图像,经过灰度化、开运算和双三次插值运算

等预处理减少图像尺寸;然后通过减少EfficientNet网络通道数构造小型网络使其具有更少参数量,以小幅降低识别率为代价达到快速识别的目的;最后将多个小型网络并行运算构成分裂EfficientNet网络EfficientNet-B0-Split3,以提升低信噪比条件下复杂多类雷达信号识别的准确率。

## 2 雷达信号预处理

### 2.1 时频分析

利用神经网络实现雷达信号调制方式识别,首先需要生成能够清晰表征信号特性的图像作为网络的输入.目前常用的雷达信号时频分析方法有STFT、Wigner-Ville分布(Wigner-Ville Distribution, WVD)和CWD等.STFT<sup>[8]</sup>算法简单,但是时域和频域分辨率不能同时兼顾,且抗噪性能差,这使得STFT在表征雷达信号特性方面效果相对较差.WVD和CWD都属于Cohen类时频分布<sup>[9,10]</sup>,此类分布通过核函数时频偏移平滑来获得更高的分辨率和去除交叉项.Cohen类时频分布定义为

$$C(t, \omega) = \frac{1}{4\pi^2} \iint A(\tau, \nu) \phi(\tau, \nu) e^{-j\nu t - j\omega \tau} d\nu d\tau \quad (1)$$

$$A(\tau, \nu) = \int x(u + \tau/2) x^*(u - \tau/2) e^{j\nu u} du \quad (2)$$

式中, $x(u)$ 是接收到的信号,\*表示共轭, $A(\tau, \nu)$ 是模糊函数, $\tau$ 和 $\nu$ 分别是时延和频移, $\phi(\tau, \nu)$ 是核函数, $t$ 和 $\omega$ 是时间和角频率。

式(1)表明,Cohen类时频分布是用核函数滤波模糊函数后信号的二维Fourier变换.WVD是核函数 $\phi(\tau, \nu) = 1$ 时的Cohen类时频分布,它具有较好的时频分辨率,且运算量适中,但存在交叉项干扰严重的问题,导致在低信噪比条件下严重影响信号调制类型的识别.因此,在利用时频图进行信号识别时,需要在保留信号调制特性的同时尽量减少信号的交叉项.CWD可以抑制信号的交叉项,降低噪声,它的核函数为 $\phi(\tau, \nu) = \exp[-(\tau\nu)^2/\sigma]$ ,其中 $\sigma$ 一般取值为1.然而,从CWD核函数的表达式可以看出,当 $\tau=0$ 或 $\nu=0$ 时, $\phi(\tau, \nu) = 1$ ,这表明CWD核函数对 $\tau$ 轴和 $\nu$ 轴没有滤波作用,仍然存在交叉项的干扰.文献[11]针对雷达调制信号主要出现在 $\tau$ 轴,而交叉项则远离 $\tau$ 轴的特点,设计了一种具有新的核函数的时频分析方法CTFD,达到了抑制信号的交叉项、降低噪声的目的.该核函数为

$$\phi(\tau, \nu) = e^{-(\alpha\tau^2 + \beta\nu^2)} \quad (3)$$

其中, $\alpha$ 和 $\beta$ 是调整核函数形状的两个参数.文献[11]中设置为 $\alpha=0.0005$ , $\beta=0.001$ .经过实验对比分析,本文选用参数 $\alpha=0.0005$ , $\beta=0.01$ 获得的时频图效果更好,时频聚集性更强,信号边界更为清晰,如图1所示。




图 1 不同频分析的 LFM 信号时频图(SNR=-6 dB)

图 1 为信噪比为-6dB 时,同一参数的 LFM 信号通过 CWD 和 CTFD 获得的时频图. 结果表明采用新核函数的 CTFD 提取的 LFM 信号受噪声影响产生的交叉项较少,信号时频图更为清晰,且本文所采用参数识别效果最优. 这是因为与 CWD 核函数相比,新核函数能更有效地滤除  $\nu$  轴噪声,调整过参数的核形状能更好地匹配雷达信号在模糊域分布特性,具有更好的抗噪声

能力.

图 2 为在信噪比为-8 dB 条件下使用 CTFD 生成 CP、LFM、NLFM 等 17 种不同调制方式的雷达信号时频图,可以发现雷达信号的细微时频特征几乎都湮没在噪声中,LFM 和 LFM+BPSK 复合调制信号, P1 和 P4, T2 和 T4, Frank 和 P3 肉眼上难以区分,且在某些参数值下, BPSK 和 T1 也会具有相似性.

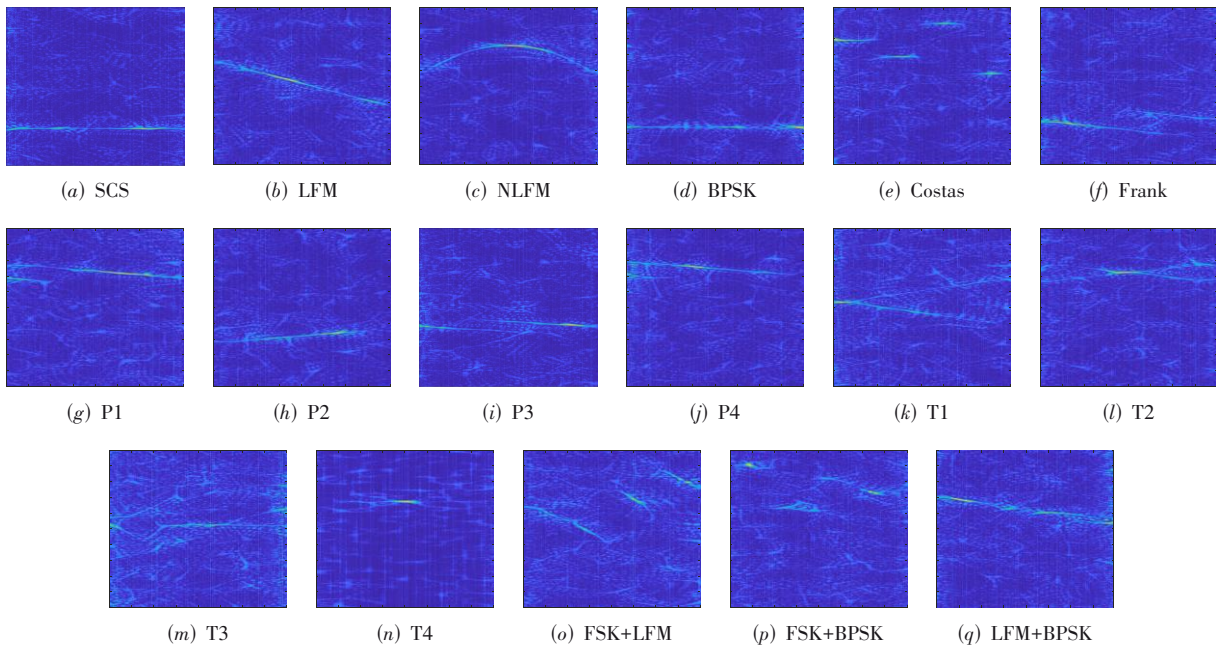


图 2 基于 CTFD 的 17 种不同调制类型信号时频图(SNR=-8 dB)

## 2.2 时频图预处理

为了减少神经网络输入维数,降低计算量,在识别前可对时频图预处理. 考虑到对信号进行过多的预处理会损失信号原有的细微特征,采用文献[12]的方法,将原始时频图像先灰度化处理减少输入通道数,再腐蚀膨胀进行开运算去除表现为特殊细长直线的进程噪声,最后利用双三次插值法将大小为  $800 \times 800$  像素的时频图像转为  $224 \times 224$  像素,以适应深度学习模型的输入要求. 对 LFM 信号 CTFD 时频图的预处理实验如

图 3 所示,第二行图像为第一行方框内部分的放大显示,可以清晰地看出进程噪声大幅降低.

## 3 分裂 EfficientNet 网络模型

### 3.1 EfficientNet 网络

2019 年, EfficientNet<sup>[13]</sup> 在分类网络中崭露头角,在 ImageNet 数据集上相近参数量的 EfficientNet 网络性能明显优于其它卷积分类网络. EfficientNet 模型的基础网络架构 EfficientNet-B0 是通过使用神经网络架构搜

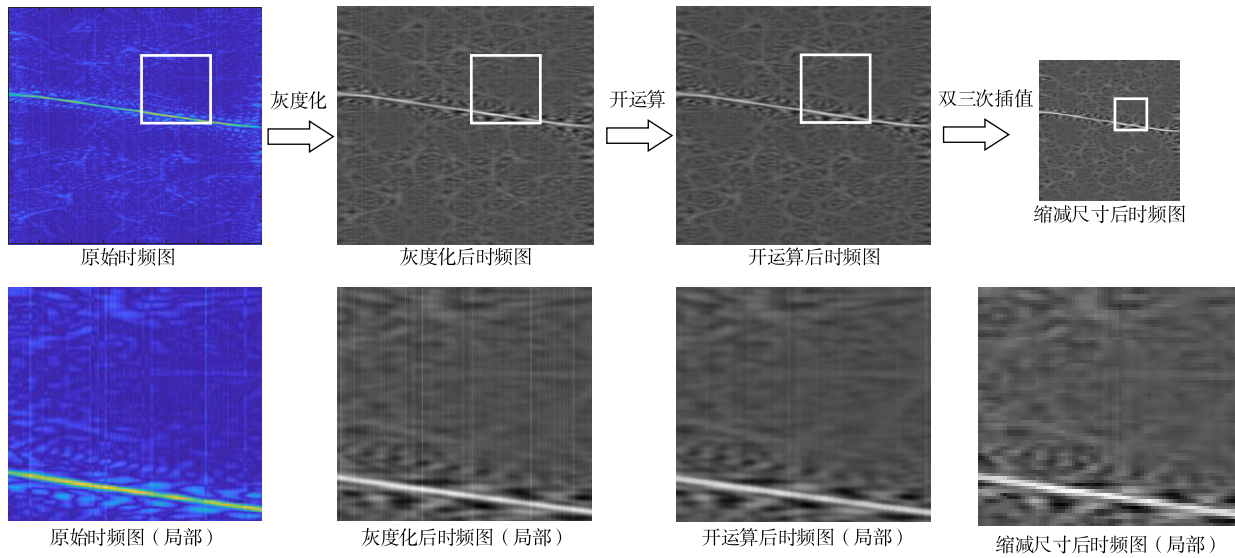


图3 LFM信号原始时频图预处理(SNR=-6 dB)

索(Neural Architecture Search, NAS)方法设计得到,该自动搜索方法通过遍历架构找到性能最优的,因此EfficientNet的基础网络架构具有优越性.深度神经网络扩展网络的宽度( $w$ )、深度( $d$ )或分辨率( $r$ )这三个任一维度都可以提高网络精度,但随着网络模型结构的不断增大,精度增长会逐渐缓慢.文献[13]研究如何进行系统地模型缩放使网络在更少参数量的情况下具有更高精度和效率,基础网络架构EfficientNet-B0以简单的恒定比例缩放每个维度实现了该目的.由于模型缩放不会改变基线网络中的层结构,本文在EfficientNet的基础网络架构EfficientNet-B0的基础上进行构建,EfficientNet-B0的网络结构图如图4(a)所示.

EfficientNet-B0网络结构主要分为9个阶段,第1阶段使用大小为 $3 \times 3$ 的卷积核共32个进行卷积,步长为 $2 \times 2$ ,即在宽和高两个方向卷积核移动步长均为2;第2阶段使用大小为 $3 \times 3$ 的卷积核,扩展比例为1的移动翻转瓶颈卷积模块(MBConv),步长为 $1 \times 1$ ;第3到8阶段是使用扩展比例为6的MBConv,并每阶段重复2、2、3、3、4、1次,每个阶段的第一次为如图4(a)标注步长,其它步长均为 $1 \times 1$ ;共由16个MBConv模块,2个卷积层(Conv),1个全局平均池化层(avg pool)和1个Softmax分类层构成.

### 3.2 分裂EfficientNet网络构建

尽管增加网络宽度可以提升网络性能,但网络的性能不会随着宽度的增加而线性提高,并且很快就会饱和.文献[14]针对这个问题提出增加网络的数量,而不是单纯地增加宽度.将一个大型网络分为若干个小网络,每个小网络与原大型网络结构相似,但只使用原始参数的一小部分,然后将这些小型网络一起训

练,并使它们处理相同数据的各种视图,以学习不同的补充知识,构建的此类网络称为分裂网络.文献[14]实验证明这些小型网络可以获得比大型网络更好的分类性能.

网络的拆分以参数量为依据,下式为一个卷积层参数量的计算方法

$$P = K^2 \times C_{in} \times C_{out} \quad (4)$$

式中, $P$ 为一个卷积层的参数量, $K$ 为使用大小为 $K \times K$ 的卷积核, $C_{in}$ 为输入通道数, $C_{out}$ 为输出通道数,如果有偏置还需再加一个 $C_{out}$ ,但是一般相对于卷积运算可以忽略不计.网络宽度与特征矩阵深度,即卷积核个数有关,由式(4)可知卷积运算的参数量几乎与网络宽度的平方( $w^2$ )成正比,因此对输入输出通道数进行调整来切分网络.

切分后的小型网络在输入训练数据时使用不同的图像变换方法,包括随机调整大小、裁剪、翻转、平移、旋转、随机擦除等,通过筛选两两组合得到十组,在数据扩充时随机选取,这样小型网络便可以在不同的数据视图下学习和训练.其中对于联合训练损失函数计算方法和总体目标函数如式(5)和(6)所示

$$\mathcal{L}_{cot}(p_1, p_2, \dots, p_s) = H\left(\frac{1}{S} \sum_{i=1}^S p_i\right) - \frac{1}{S} \sum_{i=1}^S H(p_i) \quad (5)$$

$$\mathcal{L}_{all}(p_1, p_2, \dots, p_s, y) = \sum_{i=1}^S \mathcal{L}_{ce}(p_i, y) + \lambda_{cot} \mathcal{L}_{cot}(p_1, p_2, \dots, p_s) \quad (6)$$

式中, $p_i$ 是一个小型网络的预测概率, $H(p)$ 是分布 $p$ 的香农熵, $S$ 为网络分裂出的小型网络个数, $\lambda_{cot}$ 为 $\mathcal{L}_{cot}$ 的权重因子, $\mathcal{L}_{ce}$ 为每个小型网络的测试损失函数.最后对每个小型网络的预测概率 $p_i$ 简单求平均得到最终

输出。

采用上述方法构建分裂 EfficientNet 网络。以将参数量缩减为 1/3 为例,由式(4)知更改后每阶段通道数变为原来的  $1/\sqrt{3}$ ,因此每阶段通道数由 [32, 16, 24, 40, 80, 112, 192, 320, 1 280] 缩减为 [20, 12, 16, 24, 48, 64, 112, 184, 740],命名为网络 EfficientNet-B0-Split3-1,其它网络结构通道数见表 1。然后将三个 EfficientNet-B0-Split3-1 网络并行运算,利用 Transformers 库学习不同数据视图,计算出每个小型网络的预测概率并求平均实现分类,即为网络 EfficientNet-B0-Split3,图 4 (b) 即为 EfficientNet-B0-Split3 的网络结构图,虚框内即为小型网络 EfficientNet-B0-Split3-1 的网络结构图。

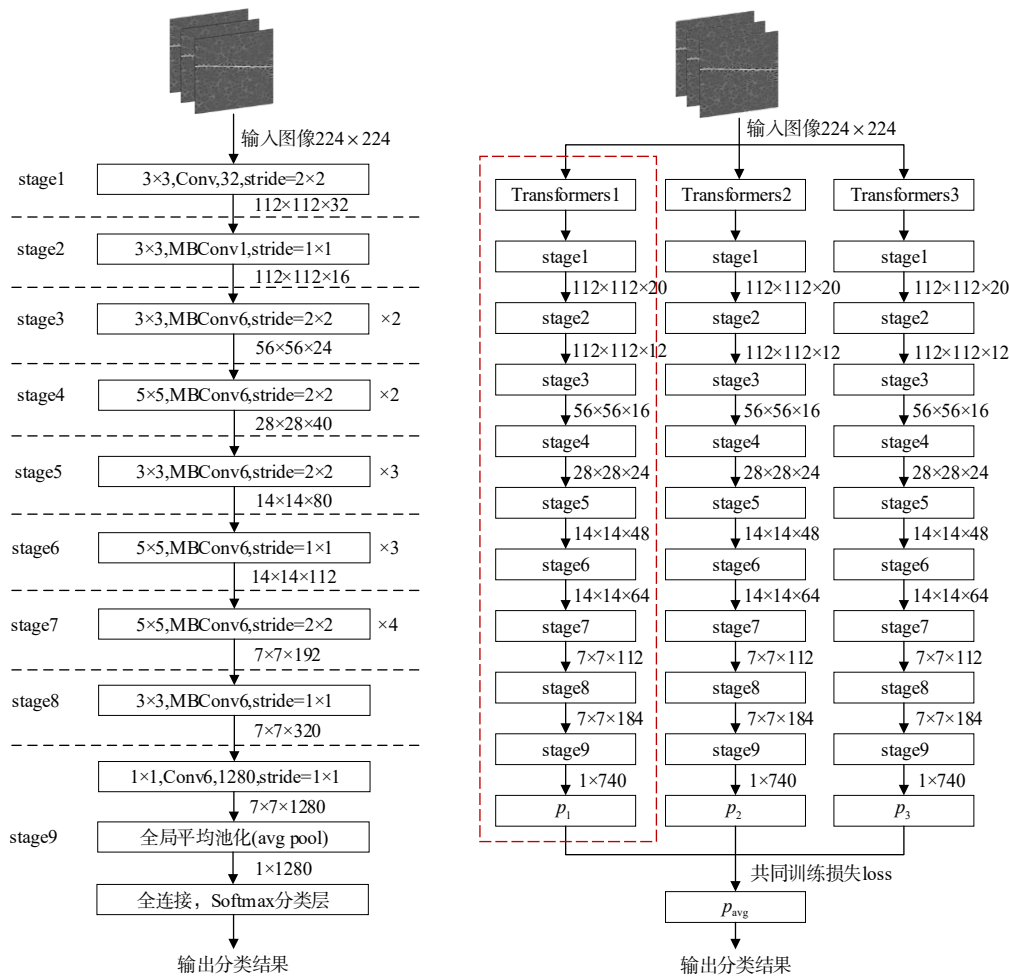
3.3 方法步骤

针对低信噪比条件下的雷达信号调制方式识别,本文基于时频分析和深度学习的识别方法,具体步骤如下:

表 1 不同网络结构通道数

网络模型	通道数
EfficientNet-B0	[32, 16, 24, 40, 80, 112, 192, 320, 1 280]
EfficientNet-B0-Split2-1	[24, 12, 16, 28, 56, 80, 136, 224, 920]
EfficientNet-B0-Split2	
EfficientNet-B0-Split3-1	[20, 12, 16, 24, 48, 64, 112, 184, 740]
EfficientNet-B0-Split3	
EfficientNet-B0-Split4-1	[16, 12, 16, 20, 40, 56, 96, 160, 640]
EfficientNet-B0-Split4	
EfficientNet-B0-Split5-1	[14, 8, 10, 18, 36, 50, 86, 144, 572]
EfficientNet-B0-Split5	
EfficientNet-B0-Split6-1	[14, 8, 10, 16, 32, 44, 78, 130, 520]
EfficientNet-B0-Split6	

(1) 首先,选择具有更好时频分析效果、参数为  $\alpha=0.0005, \beta=0.01$  的 CTFD 时频分析将信号转换为时频图,并经过灰度化、开运算和双三次插值运算等处理,按照一定规格构建数据集,并设计为训练集、验证集和



(a) EfficientNet-B0 网络结构图

(b) EfficientNet-B0-Split3 网络结构图

图 4 网络模型

测试集三部分.

(2) 根据网络参数量与网络通道数之间的关系, 通过缩减 EfficientNet-B0 通道数实现参数量成倍减少得到小型网络, 使用同一数据集对比分析小型网络 EfficientNet-B0-Split2-1 至 EfficientNet-B0-Split6-1 以及基准 EfficientNet-B0 的识别率, 从而寻找出与改进残差网络 DRN<sup>[12]</sup> 相比, 浮点数少但识别率高的小型网络.

(3) 将小型网络并行运算构成分裂 EfficientNet 网络, 通过实验寻找最优分裂数, 构建用于雷达信号调制方式识别的最佳分裂 EfficientNet 网络.

(4) 最后, 采用雷达信号参数不一致的另一组数据集验证网络分类的稳定性, 使用带内信噪比数据集验证本文网络的有效性.

本文方法整体流程如图 5 所示.

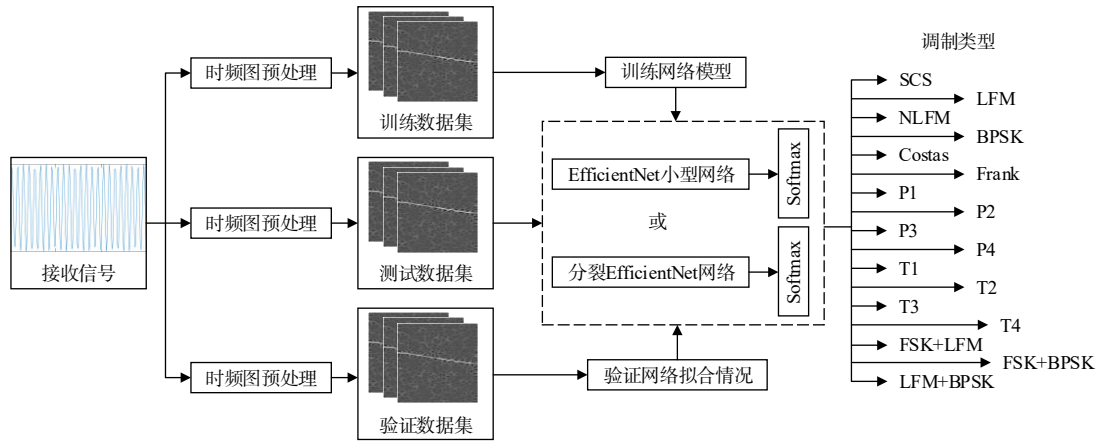


图 5 本文方法整体流程图

## 4 实验结果与分析

### 4.1 实验参数设置

本文参考文献[15]和文献[16]所描述的复杂多变雷达信号环境, 使用 Matlab R2019a 仿真 17 种雷达信号. 表 2 为 17 种信号所设置的参数范围, 仿真信号采样频率为  $f_s = 400$  MHz, 脉宽为  $p_w = 2$   $\mu$ s,  $U(a, b)$  表示信号参数在指定范围内均匀分布. 为使仿真信号尽可能与实际战场信号相近, 仿真时将信号的每个参数值设置为在指定范围内随机变化.

文献[1~7, 11, 12]中为常用的全频段功率信噪比 (full band power signal-to-noise ratio), 记为  $\text{SNR}_F$ ; 为使实验更具对比性, 本文同时采用带内功率信噪比 (in-band power signal-to-noise ratio) 进行实验, 这里简称为带内信噪比, 记为  $\text{SNR}_I$ , 带内信噪比与全频段信噪比的换算关系为

$$\begin{aligned} \text{SNR}_I &= 10 \log_{10}(B_n/B_s) + \text{SNR}_F \\ &= 10 \log_{10}(f_s/B_s) + \text{SNR}_F \end{aligned} \quad (7)$$

其中  $B_n$  为噪声带宽,  $B_s$  为信号带宽, 针对每种信号的信号带宽计算方法如下表 2 所示.

数据集 1 采用全频段功率信噪比公式计算噪声, 根据 17 种信号的参数范围 1 配置生成训练集、验证集和测试集 1, 再根据参数范围 2 配置生成测试集 2. 从全频段功率信噪比 -12 dB 到 4 dB 每 2 dB 间隔产生一组信

号, 每种类型的信号在每个全频段功率信噪比取值处产生 1 600 个样本, 以 5:2:3 的比率将它们分为训练集、验证集和测试集 1. 因此, 训练集包含  $17 \times 800 \times 9 = 122\ 400$  个样本, 验证集包含  $17 \times 320 \times 9 = 48\ 960$  个样本, 测试集 1 包含  $17 \times 480 \times 9 = 73\ 400$  个样本, 测试集 2 同样包含  $17 \times 480 \times 9 = 73\ 400$  个样本.

数据集 2 则采用带内信噪比公式计算噪声, 根据 17 种信号的参数范围 1 配置生成训练集、验证集和测试集. 从带内信噪比 0 dB 到 21 dB 每 3 dB 间隔产生一组信号, 每种类型的信号在每个带内信噪比取值处产生 1 000 个样本, 以 5:2:3 的比率将它们分为训练集、验证集和测试集. 因此, 训练集包含  $17 \times 500 \times 8 = 68\ 000$  个样本, 验证集包含  $17 \times 200 \times 8 = 27\ 200$  个样本, 测试集包含  $17 \times 300 \times 8 = 40\ 800$  个样本.

实验环境为 PyTorch1.7 框架, 操作系统为 Windows10 系统 (64 bit), CPU 为 32 核的 Intel Xeon Gold 5218, 主频为 2.30 GHz, 内存为 128 GB, GPU 为 NVIDIA Quadro RTX 5000, 专用显存为 16 GB, CUDA 版本为 11.0, cudnn 版本为 7605.

为使实验结果具有可比性, 实验统一设置初始学习率  $l_r = 0.01$ , batch size 为 64, 但因文献[17] CNN-KCRDP 基础网络模型为 AlexNet, 学习率  $l_r = 0.01$  时难以收敛, 因此 CNN-KCRDP 采用文献[17]学习率  $l_r = 0.001$ ; 优化器为随机梯度下降 (Stochastic Gradient De-

表 2 信号参数值范围

雷达信号	参数	数值范围 1	数值范围 2	信号带宽
SCS	载频 $f_c$	$U(f_s/8, f_s/2)$	$U(f_s/16, f_s/8)$	$1/p_w$
LFM NLFM	起始频率 $f_0$	$U(f_s/16, f_s/4)$	$U(f_s/20, f_s/16)$	$B_s$
	带宽 $B_s$	$U(f_s/20, f_s/4)$	$U(f_s/30, f_s/16)$	
BPSK	载频 $f_c$	$U(f_s/8, 3f_s/8)$	$U(f_s/16, f_s/8)$	$l^2/p_w$
	巴克码长度 $l$	{5, 7, 11, 13}	4	
Costas	基准频率 $f_0$	$U(f_s/30, f_s/16)$	$U(f_s/16, f_s/8)$	$N_F^2/p_w$
	跳频序列长 $N_F$	{3, 4, 5, 6}	{3, 4, 5, 6, 7}	
Frank P1~P4	载频 $f_c$	$U(f_s/8, 3f_s/8)$	$U(f_s/16, f_s/8)$	$M^3/p_w$
	步进频率 $M$	{4, 5, 6, 7, 8} (P2 码 $M$ 取偶数)	{4, 5, 6, 7, 8, 9, 10} (P2 码 $M$ 取偶数)	
T1~T4	载频 $f_c$	$U(f_s/8, 3f_s/8)$	$U(f_s/16, f_s/8)$	$k^2/p_w$
	码序列段数 $k$	{4, 5, 6, 7, 8}	{4, 5, 6, 7, 8}	
FSK+LFM	基准频率 $f_0$	$U(f_s/24, f_s/16)$	$U(f_s/16, f_s/8)$	$B_c \times m$
	子码带宽 $B_c$	$U(f_s/20, f_s/10)$	$U(f_s/30, f_s/20)$	
	进制数 $m$	4	{2, 4}	
FSK+BPSK	基准频率 $f_0$	$U(f_s/24, f_s/16)$	$U(f_s/16, f_s/8)$	$l^2 \times m / p_w$
	巴克码长度 $l$	5	7	
	进制数 $m$	4	{2, 4}	
LFM+BPSK	载频 $f_c$	$U(f_s/16, f_s/4)$	$U(f_s/20, f_s/16)$	$B_s$
	带宽 $B_s$	$U(f_s/20, f_s/4)$	$U(f_s/24, f_s/20)$	
	巴克码长度 $l$	{5, 7, 11, 13}	4	

scent, SGD), 动量为 0.9, Dropout rate 为 0.2, 权重衰减为  $5 \times 10^{-4}$ , 其中网络 EfficientNet-B0、EfficientNet-B0-Split2-1 至 EfficientNet-B0-Split6-1 的学习率下降系数为 0.8, 在经过 200 次训练后损失值不再下降, 达到稳定; 而 EfficientNet-B0-Split2 至 EfficientNet-B0-Split6 的学习率下降系数为  $0.5 + 0.5\cos(n/N)$ , 其中  $n$  为当前次,  $N$  为总训练次; 由于多小型网络间学习, 在经过 350 次训练后损失值不再下降, 达到稳定. 经过多次重复实验, 最大波动范围在  $\pm 0.2\%$  以内, 证明网络结构具有稳定性.

## 4.2 识别性能对比

### 4.2.1 不同时频分析识别效果对比

为验证本文选用参数  $\alpha=0.0005, \beta=0.01$  的 CTFD 时频分析获得的时频图效果, 分别以文献[11]参数  $\alpha=0.0005, \beta=0.001$  的 CTFD 时频分析、常用的 CWD 时频分析以及本文使用的 CTFD 时频分析, 三种时频分析按数据集 1 规格生成数据集, 以 EfficientNet-B0 网络、测试集 1 进行识别验证, 验证结果如图 6 所示. 在全频段功率信噪比为  $-2$  dB 至  $4$  dB 时, 三种时频分析方法识别率都近为 100%; 但随着全频段功率信噪比的降低可以明

显看出: 本文采用参数为  $\alpha=0.0005, \beta=0.01$  的 CTFD 时频分析识别效果最优, 文献[11]采用参数为  $\alpha=0.0005, \beta=0.001$  的 CTFD 时频分析识别效果次之, 最后是 CWD 时频分析; 在全频段功率信噪比为  $-12$  dB 时, 由于噪声影响过大, 大部分信号湮没在噪声中难以区分, 使得识别率大幅下降, 但本文 CTFD 识别率仍高于其他两种, 证明了本文采用的 CTFD 时频分析具有较好的时频分析识别效果.




图 6 不同时频分析识别效果

### 4.2.2 EfficientNet 网络分裂数寻优

为确定分裂 EfficientNet 网络最优分裂数, 使用本文构建的数据集 1、测试集 1 对网络 EfficientNet-B0、EfficientNet-B0-Split2 至 EfficientNet-B0-Split6 进行识别验证, 图 7 是全频段功率信噪比分别为  $-12$  dB、 $-10$  dB、 $-8$  dB、 $-6$  dB 时不同分裂数对应的识别率, 分裂数为 1 即为 EfficientNet-B0. 可以看出全频段功率信噪比为  $-8$  dB 及  $-6$  dB 时分裂数为 1 至 4 的识别率相差很小, 全频段功率信噪比为  $-10$  dB、 $-12$  dB 时分裂数为 3 的网络结构识别率最高. 说明小型网络数量的增加有利于信号分类识别, 尤其是低信噪比条件下, 但是随着网络数量的增加识别率降低, 对于 EfficientNet-B0 网络结构最优拆分小型网络数量为 3.

### 4.2.3 不同网络性能分析

文献[12]和文献[17]分别识别的 16 种和 12 种调制类型信号包含于本文的 17 种不同调制方式的雷达信号中, 且文献[12]具有较高雷达信号调制方式识别率. 为对比不同网络模型的性能, 选取文献[12]DRN、文献[17]CNN-KCRDP、EfficientNet-B0、EfficientNet-B0-Split2-1 至 EfficientNet-B0-Split6-1 以及 EfficientNet-B0-Split3 进行对比, 使用本文构建的数据集 1、测试集 1 进行识别, 识别结果如表 3 所示. 表 3 为全频段功率信噪比为  $-12$  dB、 $-10$  dB、 $-8$  dB 和  $-6$  dB 时本文对比的十种




图7 EfficientNet-B0网络结构不同分裂数识别率

网络模型识别率具体数值以及参数量和浮点运算量. 参数量反映了算法的空间复杂度, 浮点运算量反映了算法的时间复杂度, 深度学习中通常以这两个参数作为衡量神经网络性能的标准.

文献[17]CNN-KCRDP则因为基础网络模型采用 AlexNet, 相对本文其他网络模型参数量较大, 识别效果也不如其他网络. EfficientNet-B0-Split2-1 至

EfficientNet-B0-Split6-1 随着参数量的减少识别率呈递减趋势. 其中 EfficientNet-B0-Split4-1 因为每层通道数的改变, 参数量近似减少为 EfficientNet-B0 的 1/4, 但识别率相对于 EfficientNet-B0 仅有小幅降低; 网络结构中卷积运算仍多于 DRN, 因此参数量略高于 DRN, 但是浮点运算量却远少于 DRN, 识别率仍远高于 DRN, 在全频段功率信噪比为 -6 dB 时, 识别率为 99.2%, 高出 DRN 1.4 个百分点; 在全频段功率信噪比为 -10 dB 时, 识别率可达 91.2%, 高出 DRN 3.8 个百分点.

对于 EfficientNet-B0-Split3 则因为根据参数量对网络结构进行拆分与组合, 与 EfficientNet-B0 相比参数量几乎没有变化, 但由于增加了网络间的运算等导致浮点运算量略有提高. 在全频段功率信噪比为 -8 dB 时, EfficientNet-B0-Split3 识别率为 97.1%, 相比于 DRN 提高了 2.4 个百分点; 在全频段功率信噪比为 -10 dB 时, 识别率为 92.1%, 相比于 EfficientNet-B0 识别率提高了 0.7 个百分点, 相比于 DRN 提高了 4.7 个百分点; 在全频段功率信噪比为 -12 dB 时, 识别率仍可达 78.0%, 相比于 EfficientNet-B0 提高了 3.4 个百分点, 相比于 DRN 提高了 12.2 个百分点.

表3 识别率与复杂度分析

网络模型	SNR <sub>F</sub> = -12 dB	SNR <sub>F</sub> = -10 dB	SNR <sub>F</sub> = -8 dB	SNR <sub>F</sub> = -6 dB	参数量	浮点运算量
EfficientNet-B0	74.6%	91.4%	97.0%	99.2%	4.03M	0.24B
EfficientNet-B0-Split2-1	74.4%	91.2%	96.9%	99.1%	2.47M	0.14B
EfficientNet-B0-Split3-1	73.5%	91.1%	96.8%	99.0%	2.06M	0.13B
EfficientNet-B0-Split4-1	73.4%	91.2%	97.0%	99.2%	1.51M	0.11B
EfficientNet-B0-Split5-1	73.3%	91.0%	96.0%	99.0%	1.47M	0.10B
EfficientNet-B0-Split6-1	72.0%	90.0%	95.0%	98.0%	1.27M	0.09B
EfficientNet-B0-Split3	<b>78.0%</b>	<b>92.1%</b>	<b>97.1%</b>	99.2%	4.29M	0.29B
DRN <sup>[12]</sup>	65.8%	87.4%	94.7%	97.8%	1.49M	0.25B
CNN-KCRDP <sup>[17]</sup>	59.0%	76.5%	88.7%	94.5%	14.6M	0.31B

本文提出的两个网络模型 EfficientNet-B0-Split4-1 和 EfficientNet-B0-Split3, 参数量少和准确率高两个条件难以兼得, 因此在选取网络模型时可根据实验条件进行选取. 在时间、设备条件具备的情况下, 优先选取具有高准确率的 EfficientNet-B0-Split3; 当时间或设备条件不允许的情况下则选择参数量少的小型网络 EfficientNet-B0-Split4-1.

为更直观地对比不同网络的分类性能, 进一步分析 EfficientNet-B0、参数量与文献[12]DRN 模型相近的 EfficientNet-B0-Split4-1、EfficientNet-B0-Split3、文献[12]DRN 以及文献[17]CNN-KCRDP 对 17 类信号的识别结果, 如图 8 所示. 因为在全频段功率信噪比为 2 dB 和 4 dB 时每类信号识别率都为 100%, 为使验证结果更易观察区分, 折线图舍弃全频段功率信噪比为 2 dB 和 4 dB 时结果的绘制.

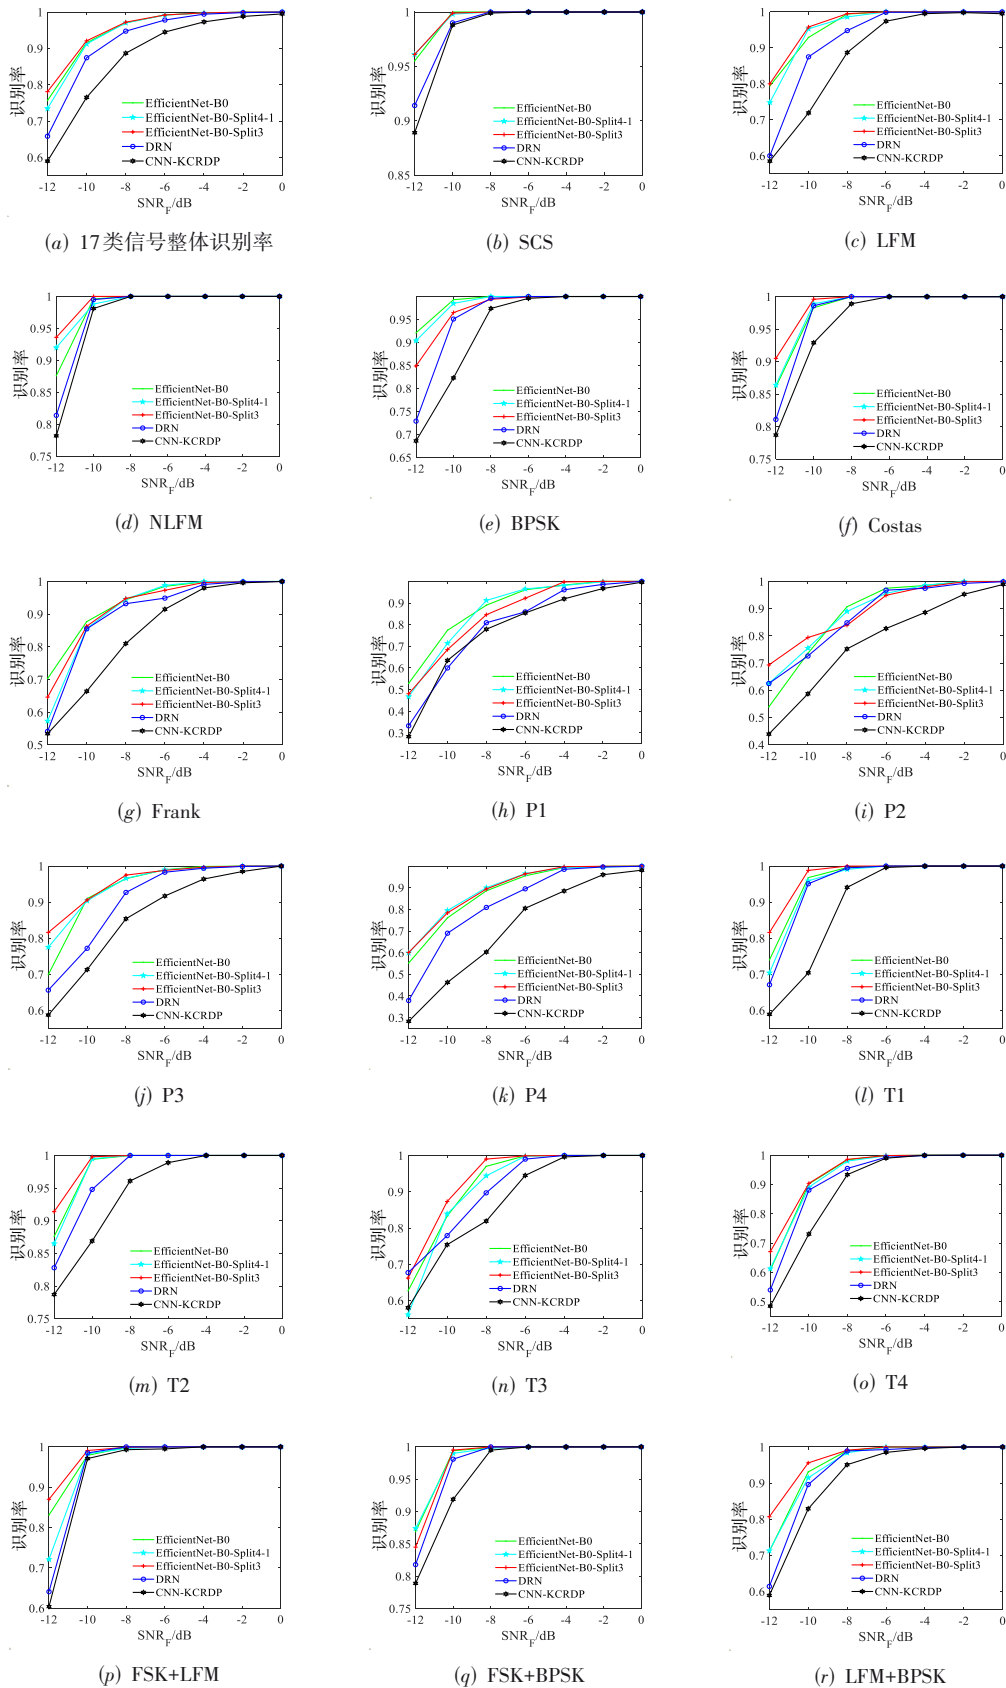


图8 不同网络模型在不同全频段功率信噪比下的识别准确度

图 8(a)为五种网络模型的整体识别率,可以看出本文所使用的网络模型识别率均优于 DRN、CNN-KCRDP,且在低信噪比下识别效果由高到低依次为 EfficientNet-B0-Split3、EfficientNet-B0 以及 EfficientNet-B0-Split4-1,证明本文所提方法具有良好的分类性能。

图 8(b)~(r)为五种网络模型对每类信号的识别率,可以看出 DRN 和 CNN-KCRDP 除对个别类型信号的某个全频段功率信噪比下识别率优于本文使用网络模型外,整体识别效果均低于本文使用网络模型识别率,且 DRN 识别率高于 CNN-KCRDP。BPSK、P1、Frank 和 FSK+BPSK 在使用多小型网络并行运算的网络模型下识别率没有高于 EfficientNet-B0,说明与 EfficientNet-B0 相比, EfficientNet-B0-Split3 在学习信号特征时重点发生偏

移,学习重点偏向调制方式复杂的信号,如 NLFM、Costas、T1~T4、FSK+LFM 及 LFM+BPSK 等。而 EfficientNet-B0-Split4-1 对每类信号的识别率与 EfficientNet-B0 接近并略微降低,与整体识别效果几乎相同。

由于文献[12]DRN 网络模型识别率高于文献[17]CNN-KCRDP 网络模型,选择 DRN 与本文网络模型 EfficientNet-B0-Split3 进一步对比信号的分类性能。图 9 为容易混淆的九种信号在全频段功率信噪比分别为 -10 dB 和 -12 dB 条件下的混淆矩阵,对角线上数值为分类正确比例,非对角线上颜色越深表示越容易分类混淆。可以看到在低信噪比条件下 P1、P2 与 P4 之间容易发生混淆,除此之外还有 Frank 和 P3、LFM 和 LFM+BPSK 之间容易发生混淆,易混淆信号与人类视觉有共

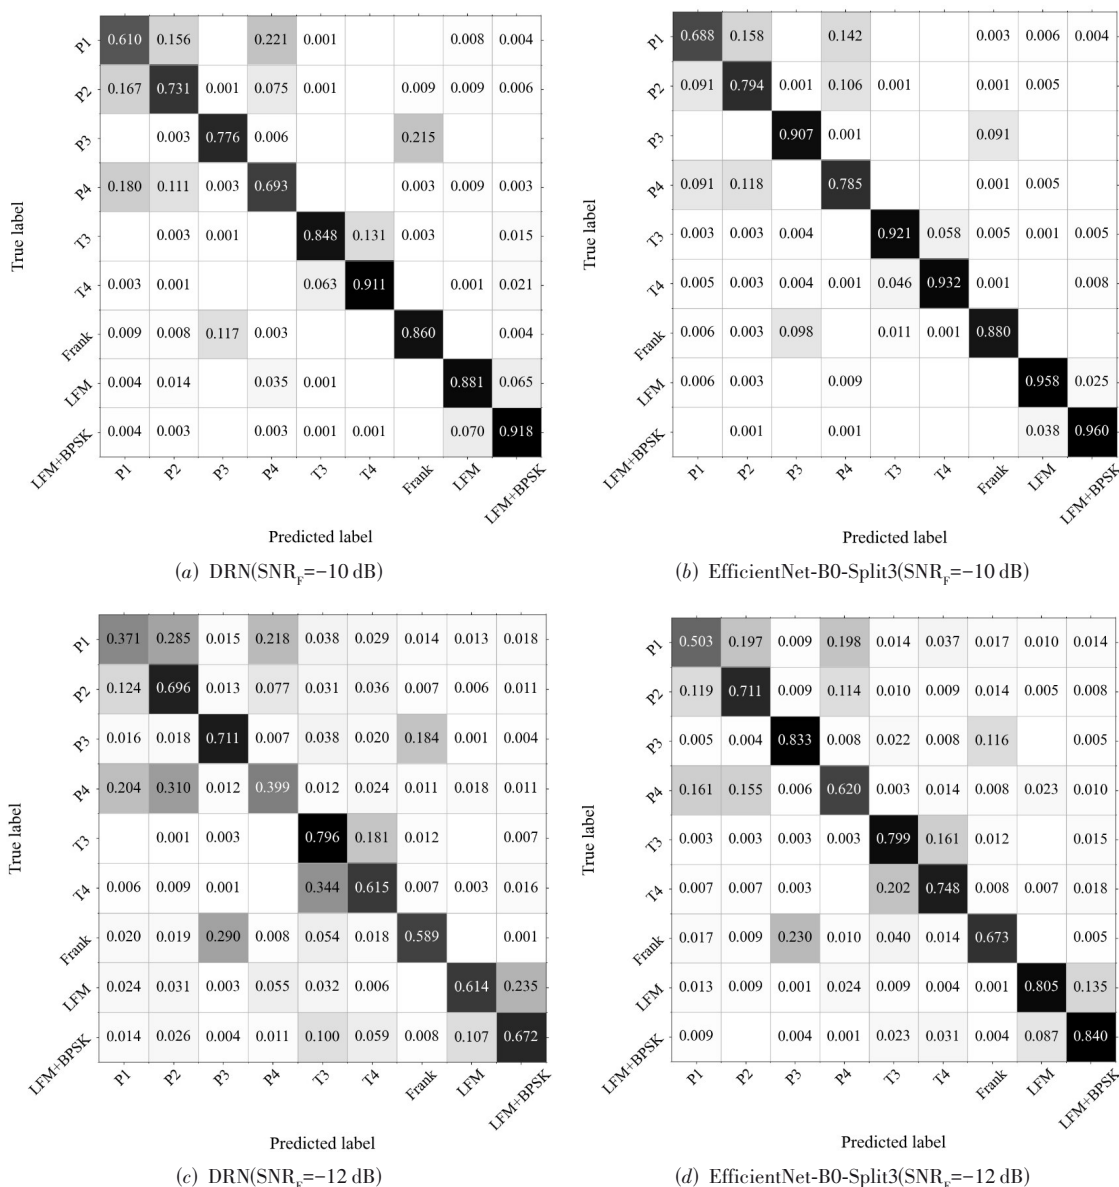


图9 不同网络模型混淆矩阵

通性. 由图 9(a)~(d)可以看出,对于容易混淆的信号本文网络模型 EfficientNet-B0-Split3 相对于文献[12] DRN 识别率都有明显提升.

为验证当训练数据集与测试数据集中雷达信号参数不一致时,深度学习网络识别性能的稳定性,将数据集 1 训练过的网络模型使用测试集 2 进行识别验证,识别结果如图 10 所示. 可以看出与使用测试集 1 得到的图 8(a) 17 类信号整体识别率相比,使用测试集 2 得到的识别率整体大幅下降,但本文网络模型 EfficientNet-B0-Split3 识别率仍相对最高,除在全频段功率信噪比为  $-6$  dB、 $-2$  dB 条件下,DRN 识别率略高于 EfficientNet-B0-Split4-1,识别率由高至低排序与图 8(a)一致,说明本文采用的深度学习网络识别性能更具稳定性.

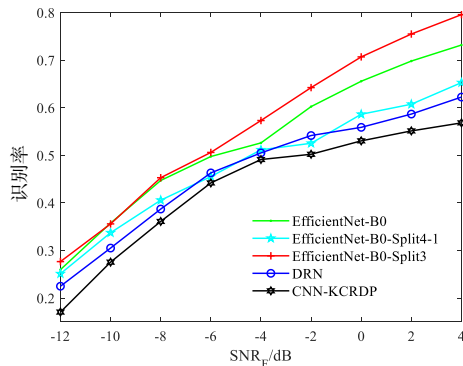


图 10 参数不一致时不同网络识别性能

为进一步验证本文网络的有效性,使用带内信噪比生成的数据集 2 对不同网络识别性能进行对比. 图 11 为在不同带内信噪比下 17 类信号的整体识别率,可以看出识别率由高至低排序与图 8(a)几乎一致,本文网络模型 EfficientNet-B0-Split3 识别率仍相对最高, EfficientNet-B0 次之,然后依次是 EfficientNet-B0-Split4-1、DRN、CNN-KCRDP,验证了本文网络的识别性能.




图 11 带内信噪比下 17 类信号整体识别率

## 5 结论

本文借助 EfficientNet 网络分类效果好的优势,提出了一种基于 CTFD 时频分析和分裂 EfficientNet 网络的雷达信号调制方式识别方法. 本文在 EfficientNet-B0 的基础上减少网络结构通道数构建小型 EfficientNet 网络,与 EfficientNet-B0 相比,在参数量和浮点运算量大大减少的前提下识别率仅有小幅降低,但识别率仍然显著优于扩张残差网络,更适用于雷达信号的快速分类识别;通过多个小型网络并行运算构建分裂 EfficientNet 网络,更有效地从时频图提取信号深层特征,相对于 EfficientNet-B0,在参数量和浮点数仅有少量增加的前提下提升了分类性能,提高了在低信噪比条件下对复杂多类雷达信号调制方式的识别率.

## 参考文献

- [1] WEI S J, QU Q Z, SU H, et al. Intra-pulse modulation radar signal recognition based on CLDN network[J]. IET Radar, Sonar & Navigation, 2020, 14(6): 803-810.
- [2] WU B, YUAN S B, LI P, et al. Radar emitter signal recognition based on one-dimensional convolutional neural network with attention mechanism[J]. Sensors (Basel, Switzerland), 2020, 20(21): 6350.
- [3] 黄颖坤, 金炜东, 余志斌, 等. 基于深度学习和集成学习的辐射源信号识别[J]. 系统工程与电子技术, 2018, 40(11): 2420-2425.
- [4] HUANG Y K, JIN W D, YU Z B, et al. Radar emitter signal recognition based on deep learning and ensemble learning[J]. Systems Engineering and Electronics, 2018, 40(11): 2420-2425. (in Chinese)
- [5] 李东瑾, 杨瑞娟, 李晓柏, 等. 基于栈式稀疏降噪自编码网络的辐射源调制识别[J]. 电子学报, 2020, 48(6): 1198-1204.
- [6] LI D J, YANG R J, LI X B, et al. Emitter signal modulation recognition based on stacked sparse denoising auto-encoders[J]. Acta Electronica Sinica, 2020, 48(6): 1198-1204. (in Chinese)
- [7] WEI S J, QU Q Z, SU H, et al. Intra-pulse modulation radar signal recognition based on Squeeze-and-Excitation networks[J]. Signal, Image and Video Processing, 2020, 14(6): 1133-1141.
- [8] LI J, ZHANG H Q, OU J P, et al. A radar signal recognition approach via IIF-Net deep learning models[J]. Computational Intelligence and Neuroscience, 2020, 2020: 8858588.
- [9] 肖易寒, 王亮, 郭玉霞. 基于去噪卷积神经网络的雷达信号调制类型识别[J]. 电子与信息学报, 2021, 43(8): 2300-

2307.

XIAO Y H, WANG L, GUO Y X. Radar signal modulation type recognition based on denoising convolutional neural network[J]. Journal of Electronics & Information Technology, 2021, 43(8): 2300-2307. (in Chinese)

- [8] 张贤达, 保铮. 非平稳信号分析与处理[M]. 北京: 国防工业出版社, 1998.
- [9] COHEN L. Time-frequency distributions-a review[J]. Proceedings of the IEEE, 1989, 77(7): 941-981.
- [10] COHEN L. Generalized phase-space distribution functions[J]. Journal of Mathematical Physics, 1966, 7(5): 781-786.
- [11] QU Z Y, MAO X J, DENG Z A. Radar signal intra-pulse modulation recognition based on convolutional neural network[J]. IEEE Access, 2018, 6: 43874-43884.
- [12] 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)
- [13] TAN M X, LE Q. EfficientNet: rethinking model scaling for convolutional neural networks[C]//International Conference on Machine Learning. California: PMLR, 2019: 6105-6114.
- [14] ZHAO Shuai, ZOU Liguang, WANG Wenxiao, et al. SplitNet: divide and co-training[EB/OL]. (2020-11-30). <https://arxiv.org/abs/2011.14660>.
- [15] 刘锋, 黄宁, 王泽众. 复杂调制信号截获、分选与识别[M]. 北京: 国防工业出版社, 2015.
- [16] 刘锋, 黄宁, 王泽众. 复杂信号侦察理论及应用-(上)[M]. 北京: 科学出版社, 2016.
- [17] LI D J, YANG R J, LI X B, et al. Radar signal modulation recognition based on deep joint learning[J]. IEEE Access, 2020, 8: 48515-48528.

牛朝阳 男, 1981年10月出生于安徽省阜阳市. 现为战略支援部队信息工程大学副教授. 主要研究方向为人工智能、雷达信号处理.

E-mail: ncy\_100@163.com

宝音图 男, 1988年10月出生于吉林省前郭市. 现为战略支援部队信息工程大学研究生. 主要研究方向为人工智能、遥感图像处理.

E-mail: bao258456@163.com

惠周勃 男, 1988年8月出生于陕西省周至市. 现为战略支援部队信息工程大学研究生. 主要研究方向为智能信号处理.

E-mail: 463700123@qq.com

## 作者简介



李 钦 女, 1996年11月出生于河南省郑州市. 现为战略支援部队信息工程大学研究生. 主要研究方向为雷达信号处理.

E-mail: liqin\_9503@163.com

刘 伟 男, 1980年6月出生于江西省萍乡市. 现为战略支援部队信息工程大学副教授. 主要研究方向为人工智能、雷达信号处理.

E-mail: greatliuliu@163.com