

基于扩张残差网络的雷达辐射源信号识别

秦 鑫, 黄 洁, 查 雄, 骆丽萍, 胡德秀

(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, 复杂多类雷达辐射源信号识别存在特征提取困难, 识别正确率低的问题, 本文提出了一种基于时频分析和扩张残差网络的辐射源信号自动识别方法. 首先通过时频分析将信号时域波形转换成二维时频图像以反映信号本质特征; 然后进行时频图像预处理以保留时频图像完备信息, 适应深度学习模型输入; 最后构建扩张残差网络以自动提取信号时频图像特征, 实现雷达辐射源信号分类识别. 实验结果表明, 信噪比为-6dB时, 该方法对16类雷达辐射源信号的整体识别正确率能够达到98.2%, 对时频图像特征相似的类LFM(Linear Frequency Modulation)信号的整体识别正确率超过95%. 本文提供了一种新的雷达辐射源信号智能识别方法, 具有较好的工程应用前景.

关键词: 新体制雷达; 雷达信号识别; 时频分析; 图像预处理; 深度学习; 扩张残差网络

中图分类号: TN971 **文献标识码:** A **文章编号:** 0372-2112 (2020)03-0456-07

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2020.03.006

Radar Emitter Signal Recognition Based on Dilated Residual Network

QIN Xin, HUANG Jie, ZHA Xiong, LUO Li-ping, HU De-xiu

(PLA Strategic Support Force Information Engineering University, Zhengzhou, Henan 450001, China)

Abstract: This paper proposes a radar emitter signal recognition method based on time-frequency analysis and dilated residual network (DRN) to solve the problem of difficulty in feature extraction and low accuracy in recognition of complex multiple radar emitter signals under low signal-to-noise ratio (SNR). Firstly, the signal time-domain waveform is transformed into a two-dimensional time-frequency image by time-frequency analysis to reflect the essential characteristics of signal. Then the time-frequency image pre-processing is carried out to retain the time-frequency image complete information and adapt to the deep learning model input. Finally, the DRN is constructed to automatically extract the signal time-frequency image features and realize the recognition of radar emitter signal. Experimental results show that when the SNR is -6dB, the overall recognition rate of the proposed method for 16 types of radar signals can reach 98.2%, and the overall recognition rate for time-frequency image similar to linear frequency modulation (LFM) signals is more than 95%. In this paper, a new intelligent recognition method for radar emitter signal is presented, which has nice engineering application prospects.

Key words: new system radar; radar signal recognition; time-frequency analysis; image pre-processing; deep learning; dilated residual network

1 引言

在现代日益密集复杂的电磁环境下, 新体制雷达层出不穷, 信号样式复杂多变, 雷达辐射源信号识别面临严峻的挑战. 传统基于脉冲描述字外部特征参数测量的辐射源信号识别手段, 已经不能满足战场上快速、准确区分辐射源信号的需求. 获取能够反映辐射源信号本质信息的脉内特征成为研究热点, 如脉内时域特征^[1]、频域特征^[2]、模糊函数特征^[3,4]、时频域特征^[5-7]等. 但人为设计提取特征的方法需要依靠专业知识和经验, 存在针对性强, 低信噪比下失效等缺陷. 因此如何自动地从数据中提

取有利于信号分类的深层本质特征亟待解决.

深度学习通过构建学习模型和海量训练数据来自动学习更具分类能力的特征, 在图像和语音信号处理领域有着重大的突破. 近年来, 国内外学者开展了将深度学习技术应用于雷达辐射源信号识别的相关研究. 文献[8~13]通过时频变换将时域信号转换成时频图像, 将雷达辐射源信号识别问题转换成图像识别问题, 进而利用深度学习技术区分不同雷达辐射源信号.

在低信噪比条件下, 此类方法较人工规则构造特征的识别方法更具鲁棒性. 但目前已有的文献仅研究了5~8类雷达辐射源信号的识别, 鲜有文献对时频图

像特征相似的类 LFM 信号 (Frank、P1、P3、P4) 进行研究. 基于此, 本文致力于探索利用深度学习技术解决复杂多类雷达辐射源信号识别问题, 包含单载频、LFM、NLFM、相位编码 (BPSK、Frank、P1 ~ P4 及 T1 ~ T4)、频率编码 Costas 和混合调制 (频率编码与 LFM 混合调制 FSK + LFM、频率编码与相位编码混合调制 FSK + BPSK) 16 类信号. 本文利用残差网络^[14] (Residual Network, ResNet) 实现复杂多类雷达辐射源信号时频图像自动分类识别, 并将 ResNet 顶层的普通卷积替换为扩张卷积构成扩张残差网络^[15] (Dilated Residual Network, DRN) 以改善低信噪比条件下类 LFM 信号的识别性能.

2 雷达辐射源信号预处理

2.1 信号时频分析

雷达辐射源信号是一种非平稳信号, 时频分析可以清晰地描述非平稳信号频率随时间变化的规律, 从

而揭示雷达辐射源信号的调制特征信息^[5]. Choi-Williams 分布 (Choi-Williams Distribution, CWD) 是采用指数加权核函数的 Cohen 类时频分布, 对不同时间或频率的信号具有较高的分辨能力和识别精度^[8]. 因此本文采用 CWD 对雷达辐射源信号进行时频变换操作.

$$\text{CWD}(t, \omega) = \iiint e^{j2\pi\xi(\mu-t)} f(\xi, \tau) \cdot x\left(\mu + \frac{\tau}{2}\right) x^*\left(\mu - \frac{\tau}{2}\right) e^{-j\omega\tau} d\xi d\mu d\tau \quad (1)$$

式中 t 和 ω 分别表示时间和角频率, $f(\xi, \tau) = e^{-\xi^2\tau^2/\sigma}$ 表示指数加权核函数, 其中 $\sigma > 0$ 为缩放因子. 为了平衡交叉项抑制和时频分辨的矛盾, 本文取 $\sigma = 1$. 图 1 表示信噪比为 8dB 时, 16 类信号的 CWD 时频分布图像, 可以看出时频图像中存在良好的信号分类属性. 其中单载频、NLFM、Costas 和混合调制信号的时频能量分布比较特殊, 与其他信号差异明显. 而对于时频图像相似度较高的信号 (Frank 码与 P3 码, P1 码与 P4 码), 信噪比较低时, 信号的时频结构破坏严重, 识别时容易产生混淆.

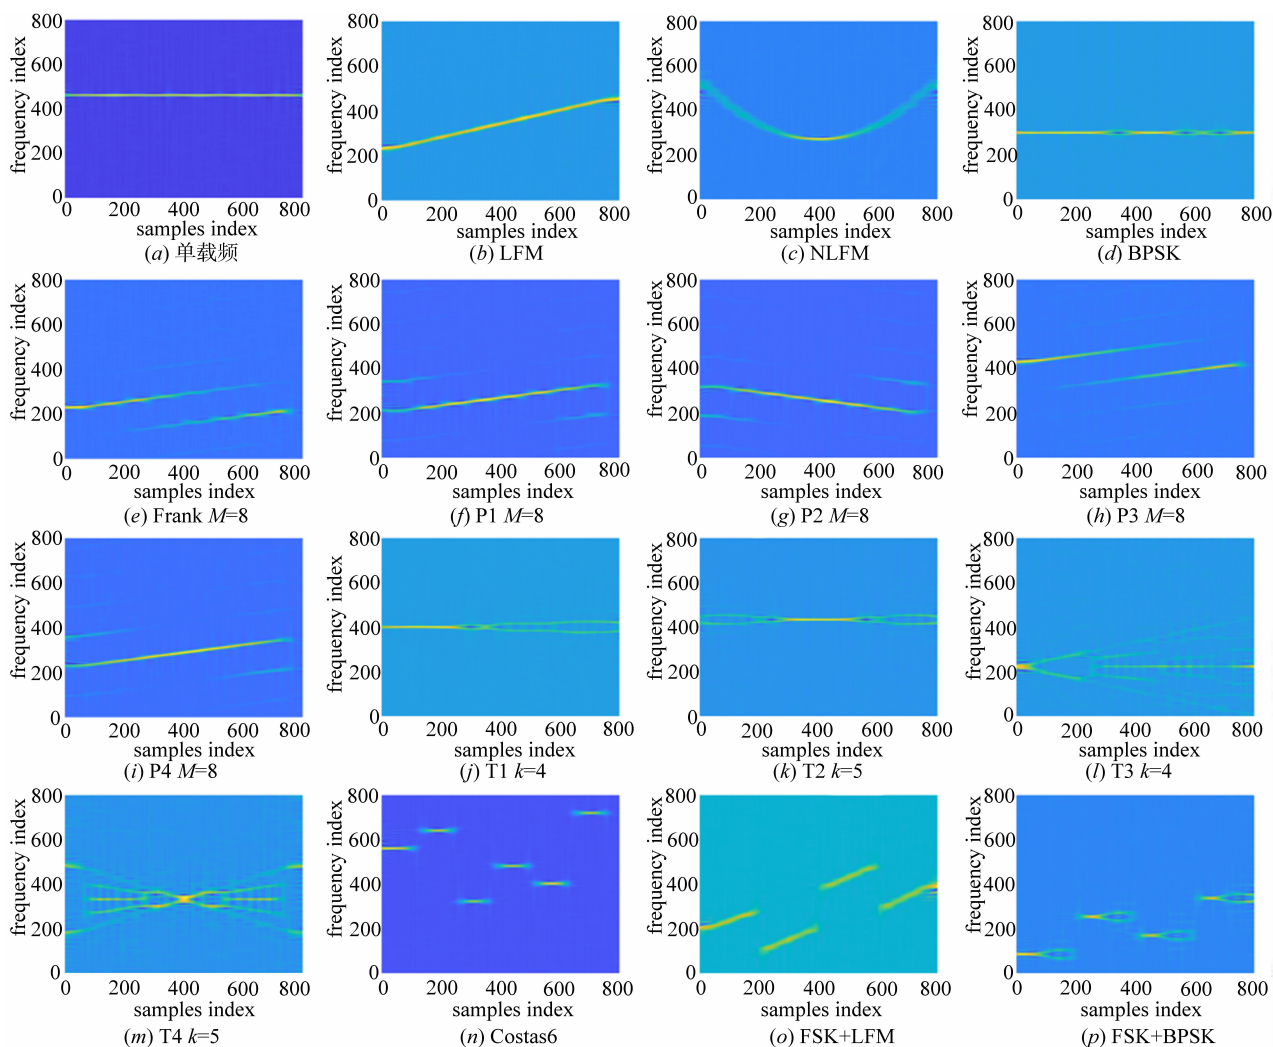
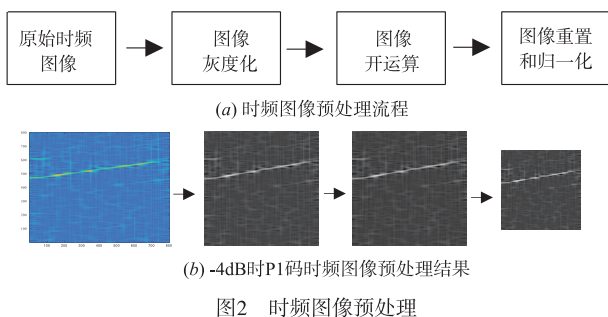


图1 16类雷达信号的CWD时频分布图像

2.2 时频图像预处理

通过 CWD 时频分析得到信号二维时频图像后,若直接利用原始时频图像进行分类识别,深度学习网络的输入维数太大,导致网络计算开销大,因此需要对时频图像进行预处理.考虑到过多的预处理将丢失信号时频图像细微信息,如 BPSK 时频脊线上的起伏, Frank、P1、P2 码时频脊线呈现出的“阶梯”变化, P1、P2、P4 码两端微弱能量值.因此本文在图像预处理时仅采取灰度化,开运算和双三次插值操作,如图 2(a)所示.

首先将信号时频能量值转化为灰度值以便完整保留信号的时频分布特征.然后选取“方形”结构元素对灰度图像做开运算以去除信噪比较低时 CWD 核函数引起的呈特殊细长直线的进程噪声^[7].最后利用双三次插值算法将大小为 800×800 的时频图像调整为 224×224 .图 2(b)为 -4dB 时 P1 码时频图像预处理结果,可以看出该流程在较为完整地保留信号时频图像特征的基础上,有效地去除了部分进程噪声,并且缩减了图像尺寸.




3 基于扩张残差网络的雷达信号识别

3.1 残差网络

深层卷积神经网络在图像识别领域取得了突破性的成果.理论上更深的网络可以提取整合更加复杂的特征,取得更好的分类效果.但是随着网络层数的加深,训练出现饱和,网络参数难以训练优化,出现了网络退化.为了解决该问题,文献[14]提出了基于短连接的残差网络 ResNet.图 3 为残差单元基本结构,其中 x 表示网络输入,输入到输出的短连接表示 x 的恒等映射, $H(x)$ 表示期望的潜在映射, $F(x) = H(x) - x$ 表示残差映射.

3.2 扩张卷积

ResNet 通过不断降低图像分辨率,直到图像被一个仅保留了微弱空间信息的特征图(一般最后卷积层输出特征图尺寸仅为 7×7)表示,最后计算类别概率来分类图像.而雷达辐射源信号时频图像的微小特征对理解图像信息十分重要,若直接使用 ResNet 会因降维太多,导致细微特征被忽略.尤其在信噪比较低时,高空间分辨率损失不利于类 LFM 信号的分类识别.基于



此本文引入扩张卷积来改善 ResNet 网络的不足,在保持原有网络感受野的基础上,维护图像空间分辨率.

在卷积神经网络中,感受野的定义为卷积神经网络每一层输出特征图上的像素点在原始图像上映射的区域大小.一般通过自顶向下进行层层迭代,直至追溯到原始输入图像来计算感受野的大小.

$$\text{RF}(n, n-i) = [\text{RF}(n, n-i+1) - 1] \times \text{stride} + k_{\text{size}} \quad (2)$$

$$i = 1, 2, \dots, n$$

式中, n 表示第 n 层卷积, $i = 1$ 时 $\text{RF}(n, n) = 1$ 表示第 n 层卷积输出特征图的 1 个像素点, $\text{RF}(n, n-i)$ 表示第 n 层卷积输出特征图的 1 个像素点在第 $n-i$ 层卷积输出特征图上的映射区域大小, stride 和 k_{size} 分别表示第 $n-i+1$ 层卷积运算步长和卷积核尺寸.迭代计算至 $i = n$ 时即得第 n 层卷积感受野 $\text{RF}(n, 0)$ 的大小.

扩张因子 rate 是卷积运算的一个重要参数, rate 值的大小决定了卷积层的计算规则.当 $\text{rate} = 1$ 时为普通卷积运算,中心像素的特征值由上一层特征图与卷积核进行点乘相加计算得到,而 $\text{rate} \neq 1$ 时中心像素的特征值由上一层特征图每隔 $\text{rate} - 1$ 个像素与卷积核点乘相加计算得到,并将其称为扩张卷积运算.从另一个角度来看扩张卷积运算相当于增大了卷积核尺寸,增幅由扩张因子的大小决定,增加的卷积核权值为 0.假设网络输入图像大小为 28×28 ,对其进行三次卷积运算,第一层使用普通卷积,二、三层使用扩张卷积.每层卷积核尺寸均为 3×3 、步长均为 1 并使用全零填充,因此特征图维度保持不变恒为 28×28 .图 4(a)~(c)分别代表三层卷积输出特征图,各层对应扩张因子分别为 1、2、4,绿色区域表示感受野大小,红色点表示卷积核有值权重.

由感受野的定义可知,第一层卷积输出特征图感受野大小与卷积核尺寸相同为 3×3 .如图 4(b)、(c)所示第二、三层卷积核尺寸分别由 3×3 增大至 5×5 , 5×5 增大至 9×9 ,增幅与扩张因子取值一致.根据式(2)计算出二、三层卷积输出特征图感受野的大小分别为 7×7 和 15×15 .扩张卷积在不使用步长的前提下能保证与普通卷积网络每一层相同大小的感受野,且输出特征图大小不变.因此本文将 ResNet 顶层普通卷积替

换为扩张卷积,构建扩张残差网络 DRN 来维护图像空间分辨率,使其不再下降,最后获得更精细的特征图以计算类别概率。




图4 卷积层运算输出

3.3 DRN 模型框架

本文基于文献[14]提出的 ResNet 来构建 DRN 模型。图 5 为本文设计的 DRN 模型,主干网络结构与 ResNet 相同,由 Input, conv1, max pool, conv2_x, conv3_x,




图5 DRN模型示意图

conv4_x, conv5_x, average pool, fc 组成,共有 5 组卷积,2 个池化层,1 个全连接层。考虑到本文待分类集合类别数为 16,输入灰度图像通道数为 1,图像大小与文献[14]相同,因此每组卷积核尺寸与文献[14]一致,但每组卷积通道数均减半,conv2_x ~ conv5_x 均只使用 1 个残差单元。并在 conv4_x、conv5_x 卷积组中分别使用扩张因子为 2、4 的扩张卷积代替普通卷积,以维护特征图空间分辨率,使其不再下降。图中虚线短连接表示残差单元的输入与输出特征图维度不匹配,此时需要采用尺寸为 1×1 的卷积核对输入特征图进行升维^[14]。为避免在训练过程中,各层激活输入值分布发生内部协变量位移,导致反向传播时神经网络底层梯度消失,本文在每层做非线性变化前先对激活输入值进行批标准化^[16],增加一个 BN 层。

4 实验结果与分析

4.1 实验参数设置

本文对 16 类雷达辐射源信号进行分类识别,仿真信号脉宽 $PW = 2\mu s$,采样率 $f_s = 400MHz$,不同信号的具体参数设置如表 1 所示,所有参数均在取值范围内随机选取。信噪比范围为 $-8 \sim 8dB$,步长为 2dB,每个信噪比下,16 类信号各随机生成 1000 个脉冲。然后对脉冲信号进行 CWD 时频分析和时频图像预处理,生成训练数据集。利用训练数据对 DRN 模型进行离线训练,待模型稳定后,保存模型。对算法性能进行测试时,在每个信噪比下,16 类信号各产生 1000 个脉冲,每类信号进行 1000 次识别测试。

4.2 不同方法识别性能对比

本节测试 DRN 模型对 16 类雷达辐射源信号的识别性能,并与另两种基于 CWD 时频分析的雷达辐射源信号识别方法进行对比。对比方法分别为文献[8]和[7]所提出的方法,其中文献[8]利用两层稀疏自编码器自动提取二值 CWD 图像特征来实现辐射源信号识别,文献[7]则通过人工设计提取二值 CWD 时频图像来实现辐射源信号识别。图 6 为 3 种方法对 16 类信号

整体的识别正确率曲线。

表 1 信号参数设置

雷达信号	参数	取值范围
单载频	载频 f_c	$[1/8, 3/8]f_s$
LFM NLFM (偶二次调频)	起始频率 f_0	$[1/16, 3/16]f_s$
	带宽 B	$[1/16, 3/16]f_s$
BPSK	载频 f_c	$[1/8, 3/8]f_s$
	巴克码长度	$\{5, 7, 11, 13\}$
Frank P1 ~ P4	载频 f_c	$[1/8, 3/8]f_s$
	步进频率 M	$\{4, 5, 6, 7, 8\}$ (P2 码 M 取偶数)
T1 ~ T4	载频 f_c	$[1/8, 3/8]f_s$
	码序列段数 k	$\{4, 5, 6, 7, 8\}$
Costas	基准频率 f_0	$[1/24, 1/16]f_s$
	跳频序列 N_F	$\{3, 4, 5, 6\}$
FSK + LFM	基准频率 f_0	$[1/24, 1/16]f_s$
	子码带宽 B_c	$[1/20, 1/10]f_s$
FSK + BPSK	基准频率 f_0	$[1/24, 1/16]f_s$

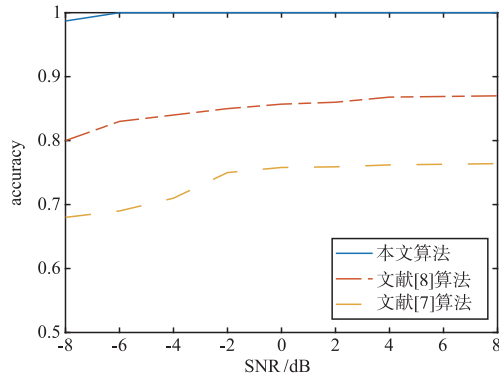


图6 不同方法识别正确率对比

由图6可知,信噪比为 -6dB 时,本文方法对16类信号的整体识别正确率能够达到 98.2% ,在 -2dB 时识别正确率接近 100% .在不同信噪比条件下,本文方法的识别正确率均高于文献[8]和文献[7]所提出的方法.文献[8]使用阈值法来获得二值时频图像,并对二值图像反复去噪导致时频图像信息损失严重,信号时频结构被破坏.文献[7]提取二值图像骨架特征作为分类特征参数集,受噪声影响较大,低信噪比下,识别性能下降明显,对各类信号的识别正确率较低;并且未对固定载频、NLFM、多时码T1~T4和混合调制信号时频图像特征进行研究,该方法不适用于上述信号的识别.本文方法在时频图像预处理过程中,选择以灰度图像作为DRN的输入,可以完整保留信号的时频分布信息;并且利用扩张卷积维护网络顶层特征图空间分辨率来构建多隐

层DRN模型,有利于学习信号细微特征,在低信噪比条件下对各类信号仍能保持高识别正确率.

4.3 不同网络模型识别性能对比

为了进一步验证DRN模型能够获得更精确的识别结果,本节将DRN模型同当前在图像识别领域表现优异的深度模型CNN^[12,13]和ResNet^[14]进行对比.测试的三种深度网络模型具有相同的卷积层、池化层、批标准化层设置,区别在于ResNet和CNN在conv4_1、conv5_1使用stride=2进行下采样,ResNet在CNN的基础上增加了短连接,DRN在ResNet的基础上将conv4_x、conv5_x中的普通卷积运算替换为扩张卷积运算.实验结果如图7所示.

图7(a)是三种模型对16类信号的整体识别正确率,可以看到三种模型均表现出较传统方法和简单深度学习模型更优越的识别性能,在不同信噪比条件下识别正确率均超过 90% .但在低信噪比条件下,DRN模型对16类信号的整体识别性能相对更优,主要原因是DRN更能准确区分时频图像特征相似的类LFM信号,如图7(b)~(f)所示.低信噪比条件下,CNN和ResNet模型最终用于分类的特征图大小仅为 7×7 ,空间分辨率低导致“看不清”类LFM信号时频脊线上细小的“阶梯”变化以及两端微弱的能量值,即降维太多不利于类LFM信号的分类识别.而DRN模型最终用于分类的特征图大小为 28×28 ,空间分辨率较高,有利于学习时频图像微小特征,因此对类LFM信号的识别更精确.

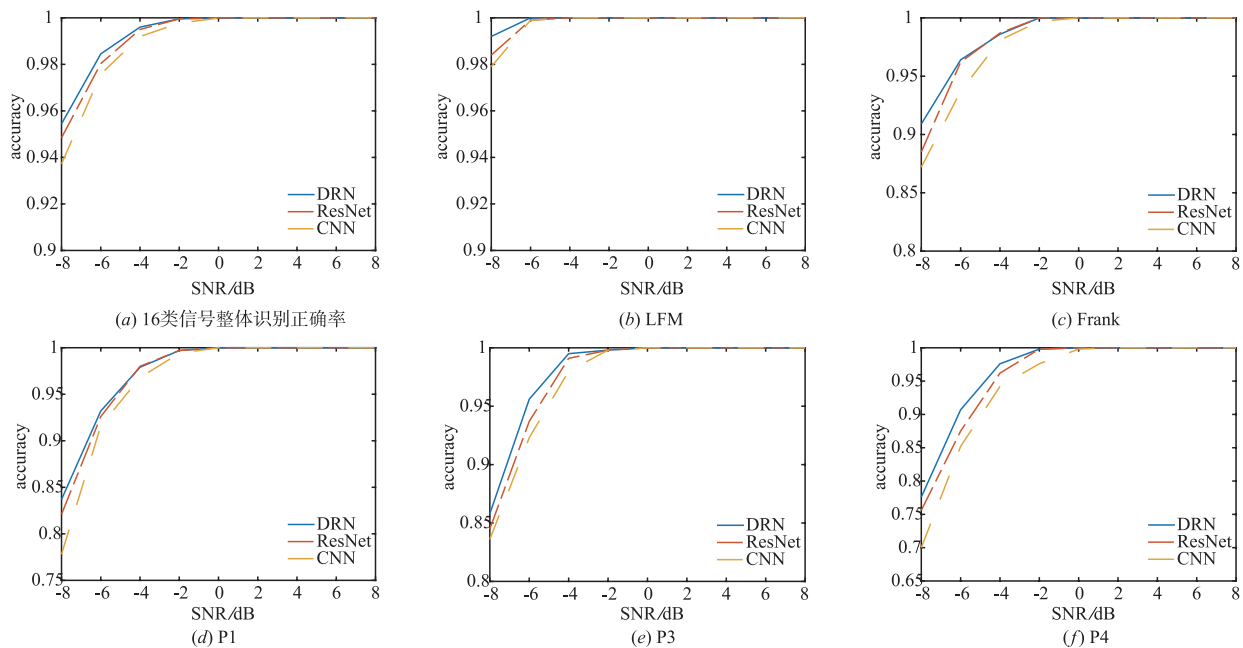


图7 不同模型对类LFM信号的识别准确率对比

为了进一步比较DRN、ResNet和CNN在识别类LFM信号上的性能差异,图8给出了在信噪比为 -6dB

时,三种模型识别类LFM信号的混淆矩阵.从图中可以看出三种模型均容易混淆Frank码和P3码、P1码和P4

码两组信号,它们的差异仅表现为时频脊线上有无“阶梯”变化;其次容易忽略 P1 和 P4 码时频分别两端微弱的能量值,从而将其判为 LFM 信号. 三种模型中 DRN 的识别正确率最高,在 -6dB 时对类 LFM 信号的整体识别正确率超过 95%,高出 ResNet 约 1.2%,CNN 约

2.6%. 由此验证了 DRN 模型在雷达辐射源信号识别中的优势:利用扩张卷积来维护网络顶层特征图的空间分辨率,使最后用于分类的特征图更精细,从而取得更高的识别正确率.

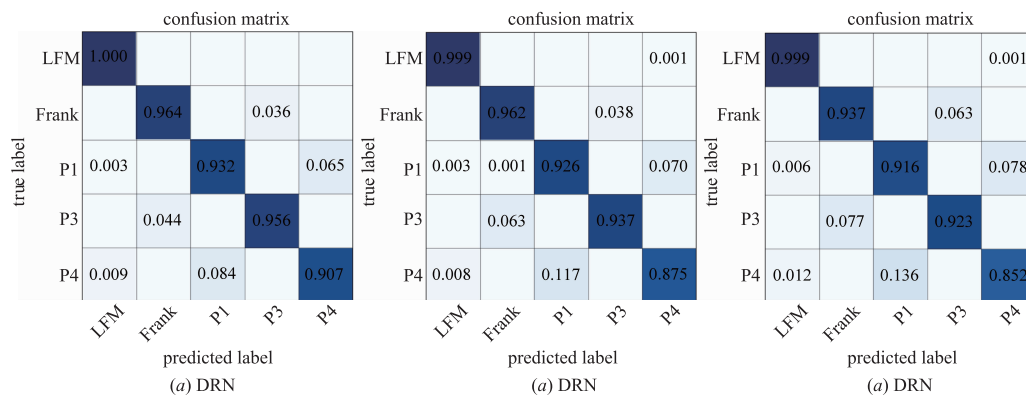


图8 不同模型识别类LFM信号的混淆矩阵

模型训练和测试均在 CPU 为 Intel (R) Xeon (R) E5-2603, GPU 为 NVIDIA Quadro K400, 内存 16GB 的环境下进行. 表 2 为不同模型的复杂度分析, 空间复杂度是指网络模型待训练的参数量, 主要由卷积层和全连接层的参数量决定. DRN 和 ResNet 参数量相同, 但虚线短连接处使用了卷积升维操作, 因此参数量略高于 CNN. 时间复杂度从每轮迭代训练耗时和识别耗时两方面进行度量, 其中每轮迭代训练耗时取 10000 轮迭代过程中每轮迭代耗时的统计平均. 从表中数据来看, DRN 在空间复杂度和时间复杂度上与 ResNet、CNN 的差异并不大, 识别耗时均在 ms 量级上, 均能够做到实时识别, 且 DRN 能够取得更高的识别正确率.

表 2 复杂度分析

模型	空间复杂度		时间复杂度	
	参数量(M)		每轮迭代 训练耗时(s)	识别耗时 (ms)
DRN	1.23		0.72	0.64
ResNet	1.23		0.53	0.40
CNN	1.19		0.49	0.38

5 结论

本文借助深度学习技术自身的优势, 提出了一种基于 CWD 时频分析和扩张残差网络的雷达辐射源信号自动识别方法, 有效地解决了特征提取困难的问题. 该方法克服了传统人工提取特征的方法对信号质量要求高, 针对性强等缺陷. 相对于其他文献所提及的神经网络结构扩张残差网络具有更强的特征学习表征能力, 并且引入扩张卷积提高了时频图像特征相似的类


LFM 信号识别正确率. 实验证明, 本文方法较其他方法在抗噪性能上有进一步的提升, 识别结果精确, 鲁棒性强.

参考文献

- [1] 陈惠民, 盛骥松. 一种新的雷达信号分选方法[J]. 现代电子技术, 2009, 32(01): 20-22.
CHEN Hui-min, SHENG Ji-song. New method of classifying the radar signals[J]. Modern Electronics Technique, 2009, 32(01): 20-22. (in Chinese)
- [2] 韩立辉, 黄高明. 基于倒谱分析的雷达信号脉内调制识别[J]. 电子信息对抗技术, 2011, 26(03): 29-32.
HAN Li-hui, HUANG Gao-ming. Intrapulse modulation recognition of radar signals based on cepstrum analysis [J]. Electronic Information Warfare Technology, 2011, 26(03): 29-32. (in Chinese)
- [3] Guo Q, Nan P, Zhang X, et al. Recognition of radar emitter signals based on SVD and AF main ridge slice[J]. Journal of Communications & Networks, 2015, 17(5): 491-498.
- [4] 许程成, 周青松, 等. 导数约束平滑条件下基于模糊函数特征的雷达辐射源信号识别方法[J]. 电子学报, 2018, 46(7): 1663-1668.
XU Cheng-cheng, ZHOU Qing-song, et al. Radar emitter recognition based on ambiguity function features with derivative constraint on smoothing[J]. Acta Electronica Sinica, 2018, 46(7): 1663-1668. (in Chinese)
- [5] 朱健东, 张玉灵, 赵拥军. 基于时频图像处理提取瞬时频率的雷达信号识别[J]. 系统仿真学报, 2014, 26(4): 864-868.
ZHU Jian-dong, ZHANG Yu-ling, ZHAO Yong-jun. Instan-

- taneous frequency based radar signals recognition using time frequency image processing [J]. Journal of System Simulation, 2014, 26(4): 864 - 868. (in Chinese)
- [6] 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.
- [7] ZHANG Ming, LIU Lu-tao, DIAO Ming. LPI radar waveform recognition based on time-frequency distribution [J]. Sensors, 2016, 16(10): 1682.
- [8] 郭立民, 寇韵涵, 陈涛, 等. 基于栈式稀疏自编码器的低信噪比下低截获概率雷达信号调制类型识别 [J]. 电子与信息学报, 2018, 40(4): 875 - 881.
GUO Li-min, KOU Yun-han, CHEN Tao, et al. Low probability of intercept radar signal recognition based on stacked sparse auto-encoder [J]. Journal of Electronics & Information Technology, 2018, 40(4): 875 - 881. (in Chinese)
- [9] 黄颖坤, 金伟东, 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): 33 - 38.
HUANG Ying-kun, JIN Wei-dong, YU Zhi-bin, et al. Radar emitter signal recognition based on deep learning and ensemble learning [J]. Systems Engineering and Electronics, 2018, 40(11): 33 - 38. (in Chinese)
- [10] 周志文, 黄高明, 高俊, 等. 一种深度学习的雷达辐射源识别算法 [J]. 西安电子科技大学学报(自然科学版), 2017, 44(3): 77 - 82.
ZHOU Zhi-wen, HUANG Gao-ming, GAO Jun, et al. Radar emitter identification algorithm based on deep learning [J]. Journal of Xidian University, 2017, 44(3): 77 - 82. (in Chinese)
- [11] 叶文强, 俞志富, 张奎. 基于 DAE + CNN 辐射源信号识别算法 [J]. 计算机应用研究, 2019, 36(12): 1 - 1.
YE Wen-qiang, YU Zhi-fu, ZHANG Kui. Recognition algorithm of emitter signal based on DAE + CNN [J]. Application Research of Computers, 2019, 36(12): 1 - 1. (in Chinese)
- [12] Zhang M, Diao M, Guo L. Convolutional neural networks for automatic cognitive radio waveform recognition [J]. IEEE Access, 2017, 5: 11074 - 11082.
- [13] Kong S H, Kim M, Hoang L M. Automatic LPI radar waveform recognition using CNN [J]. IEEE Access, 2018, 6: 4207 - 4219.
- [14] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition [A]. Computer Vision and Pattern Recognition [C]. US: IEEE, 2016. 770 - 778.
- [15] Yu F, Koltun V, Funkhouser T. Dilated residual networks [A]. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) [C]. Honolulu, HI, USA: IEEE, 2017. 636 - 644
- [16] Ioffe S, Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift [A]. International Conference on Machine Learning [C]. Lille, France: JMLR, 2015. 448 - 456.

作者简介



秦 鑫 女, 1994 年出生, 重庆人. 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: qinxin_0920@163.com

查 雄 男, 1995 年出生, 江西九江人. 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.

黄 洁 女, 1973 年出生, 河南郑州人. 现为战略支援部队信息工程大学教授、硕士生导师, 主要研究方向为信息融合、模式识别.

骆丽萍 女, 1978 年出生, 四川新津人. 现为战略支援部队信息工程大学讲师, 主要研究方向为雷达信号处理、模式识别.