

文章编号:1007-5321(2021)06-0074-09

DOI:10.13190/j.jbupt.2021-055

# 基于多学习单元卷积神经网络的雷达辐射源信号识别

普运伟<sup>1,2</sup>, 郭江<sup>1</sup>, 刘涛涛<sup>1</sup>, 吴海潇<sup>1</sup>

(1. 昆明理工大学 信息工程与自动学院, 昆明 650500; 2. 昆明理工大学 计算中心, 昆明 650500)

**摘要:** 现有基于人工提取特征的复杂体制雷达辐射源信号识别方法时效性低, 识别准确率不佳. 为此, 提出了一种基于多学习单元卷积神经网络的识别方法. 首先对辐射源信号的模糊函数进行高斯平滑, 以校正噪声带来的毛刺与畸变; 然后提取其正交切片作为进一步的特征提取对象; 最后构建多学习单元卷积神经网络, 学习和提取正交切片深层、泛在的特征, 并通过 softmax 分类器进行分类识别. 仿真实验结果表明, 所提方法在信噪比为 -2 dB 时对 6 类典型雷达信号的整体平均识别率均保持在 99.86% 以上, 即便是在 -6 dB 环境中, 雷达信号的识别率也可达到 88.50%, 在极低信噪比条件下具有良好的性能和可行性.

**关键词:** 雷达辐射源信号; 模糊函数; 信号识别; 深度学习; 多学习单元卷积神经网络

中图分类号: TN974

文献标志码: A

## A Recognition Method for Radar Emitter Signals Based on Convolutional Neural Network with Multiple Learning Units

PU Yun-wei<sup>1,2</sup>, GUO Jiang<sup>1</sup>, LIU Tao-tao<sup>1</sup>, WU Hai-xiao<sup>1</sup>

(1. Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650500, China;

2. Computer Center, Kunming University of Science and Technology, Kunming 650500, China)

**Abstract:** Existing radar emitter signal recognition methods based on manually extract features have problems including low timeliness and poor recognition rate. To address these issues, a new recognition method based on a convolutional neural network with multiple learning units is proposed. First, the burr and distortion caused by noise of ambiguity function of emitter signals are corrected through the Gaussian smoothing. Then, the orthogonal slice is extracted as the further feature extraction objects. Finally, a convolutional neural network with multiple learning units is built to learn and extract the deep and ubiquitous features of the orthogonal slice, which are further classified through the softmax classifier. Simulation results show that the overall average recognition rate of six typical radar signals are all above 99.86% when the signal-to-noise ratio is -2 dB. The recognition rate can reach up to 88.50% when the signal-to-noise ratio is -6 dB. The results prove the good performance and feasibility of the proposed method when signal-to-noise ratio is extremely low.

**Key words:** radar emitter signals; ambiguity function; signal recognition; deep learning; convolutional neural network with multiple learning units

雷达辐射源信号识别是指从截获的敌方雷达信号中分选出单部雷达信号后, 将分选后的信号特征参

收稿日期: 2021-04-02

基金项目: 国家自然科学基金项目(61561028)

作者简介: 普运伟(1972—), 男, 教授, 博士生导师, E-mail: puyunwei@126.com.

数与先验信息库进行比较匹配的过程. 近年来, 出现了各种复杂体制的雷达, 雷达辐射源信号表现出调制类型复杂化、参数快变化、波形多样化等情况. 只依靠脉冲宽度 (PW, pulse width)、到达角度 (DOA, direction of arrival)、载波频率 (RF, radio frequency)、脉冲幅度 (PA, pulse amplitude) 和到达时间 (TOA, time of arrival) 5 个常规参数进行识别已很难满足实际需求. 因此, 从更为深入的方向提取快速而有效的脉内特征参数是值得关注的出发点. 模糊函数 (AF, ambiguity function) 是一种研究雷达信号的有效方法, 包含了信号较为丰富的时频域信息. 时羽等<sup>[1]</sup>采用优势遗传的智能搜索算法对 AF 主脊切面进行搜索, 提取了表征信号模糊能量分布特征的矩特征, 分选精度较高, 但二次搜索增加了算法的复杂度. Guo 等<sup>[2]</sup>通过奇异值分解 (SVD, singular value decomposition) 对辐射源信号进行去噪, 提取 Holder 系数作为分选特征, 但当信号功率接近噪声功率时, SVD 对切片波形特征的抗噪性能不佳. 普运伟等<sup>[3]</sup>对辐射源信号的 AF 从主、侧视角出发, 提取了 AF 的三维特征, 减小了搜索 AF 最大能量切面所需的问题规模和算法复杂度, 但信息利用率和分选准确率较低. 当前, 深度神经网络 (DNN, deep neural network) 已广泛应用于图像识别<sup>[4]</sup>等领域. Qu 等<sup>[5]</sup>提取了辐射源信号的时频图像, 并通过深度 Q 网络进行特征学习与分类, 达到了较高的识别精度, 但网络结构复杂, 需要的训练样本量太大. Ding 等<sup>[6]</sup>构建了深度卷积网络对辐射源的双谱特征进行了有效识别, 但网络抗噪性能不佳, 在低信噪比下识别效果有待提升.

为解决上述方法在极低信噪比条件下识别性能不足的问题, 构建了多学习单元卷积神经网络 (CNN, convolutional neural network), 用以学习模糊函数正交切片 (AFOS, ambiguity function orthogonal slice) 的内在特征规律, 提取其深层模糊能量的特征, 进一步准确识别辐射源信号. 实验结果表明, 此方法的抗噪性能较强, 且在极低信噪比下仍可达到满意的识别效果.

## 1 模糊函数正交切片

### 1.1 模糊函数

辐射源信号  $s(t)$  的 AF 可以视为其瞬时自相关函数关于时间  $\tau$  的傅里叶反变换<sup>[7]</sup>, 有

$$\chi(\tau, \xi) = \int_{-\infty}^{+\infty} s\left(t + \frac{\tau}{2}\right) s^*\left(t - \frac{\tau}{2}\right) e^{-j2\pi\xi t} dt \quad (1)$$

其中:  $s^*(t)$  为  $s(t)$  的共轭,  $\tau$  为时延,  $\xi$  为频移. 可见, 信号的 AF 是信号在时域和频域平面上的联合二维时频表示.

### 1.2 模糊函数的高斯平滑处理

从三维空间中观察到, 强噪声的影响使得 AF 产生了大量的畸变和毛刺, 极大地增加了辐射源信号识别的难度. 考虑到高斯滤波器对毛刺现象有较好的平滑效果<sup>[8]</sup>, 可构建高斯掩膜对 AF 进行降噪处理.

#### 1.2.1 构建高斯掩膜

对第  $i$  行, 第  $j$  列任意网格点  $(i, j)$  对应的  $\chi(i, j)$  进行平滑处理后, 有

$$\bar{\chi}(i, j) = \frac{\sum w(a, b) \chi(i, j)}{\sum w(a, b)} \quad (2)$$

其中:  $w$  为网格点  $(i, j)$  附近一定范围的掩膜,  $w(a, b)$  为掩膜内的权重因子, 表达式为

$$w(a, b) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left[-\frac{(a^2 - b^2)}{2\sigma^2}\right] \quad (3)$$

其中:  $a, b$  为权重因子的位置,  $\sigma$  为标准差.

#### 1.2.2 选取掩膜参数

在平滑阶段, 高斯掩膜的尺寸 ( $M$ ) 和标准差 ( $\sigma$ ) 是 2 个重要参数, 高斯掩膜是对连续高斯函数的离散近似, 掩膜越大, 近似区间越大, 卷积过程的乘法次数也越多. 常用的掩膜尺寸为  $3 \times 3$ 、 $5 \times 5$  和  $7 \times 7$ , 考虑到计算量和复杂度,  $5 \times 5$  的掩膜尺寸较为合理.

标准差直观表现为掩膜对 AF 的平滑效果, 其取值越大, AF 越平滑, 但图像的细微信息丢失也越多, 因而标准差的大小取决于问题背景. 高斯平滑主要用于消除噪声给 AF 带来的畸变和毛刺现象, 采用  $5 \times 5$ ,  $\sigma = 1$  的高斯掩膜, 分别在 0 dB 和 20 dB 情况下对线性调频 (LFM, linear frequency modulation) 信号的 AF 进行平滑处理, 处理前后的对比如图 1 所示. 可见, 由于受强噪声的影响, LFM 信号的 AF 失真较为严重, 增加了辐射源信号的识别难度, 但通过平滑处理以后, 毛刺与畸变明显变少. 并且, 高斯函数服从  $N(\mu, \sigma^2)$  分布,  $\sigma$  越小, 分布越集中在  $\mu$  附近;  $\sigma$  越大, 分布越分散. 考虑到当  $\mu = 0$ ,  $\sigma = 1$  时, 高斯钟形曲线服从标准正态分布, 使得  $5 \times 5$  大小的掩膜对 AF 的平滑覆盖范围较广. 综合分析, 高斯掩膜的参数选择为  $5, \sigma = 1$ .

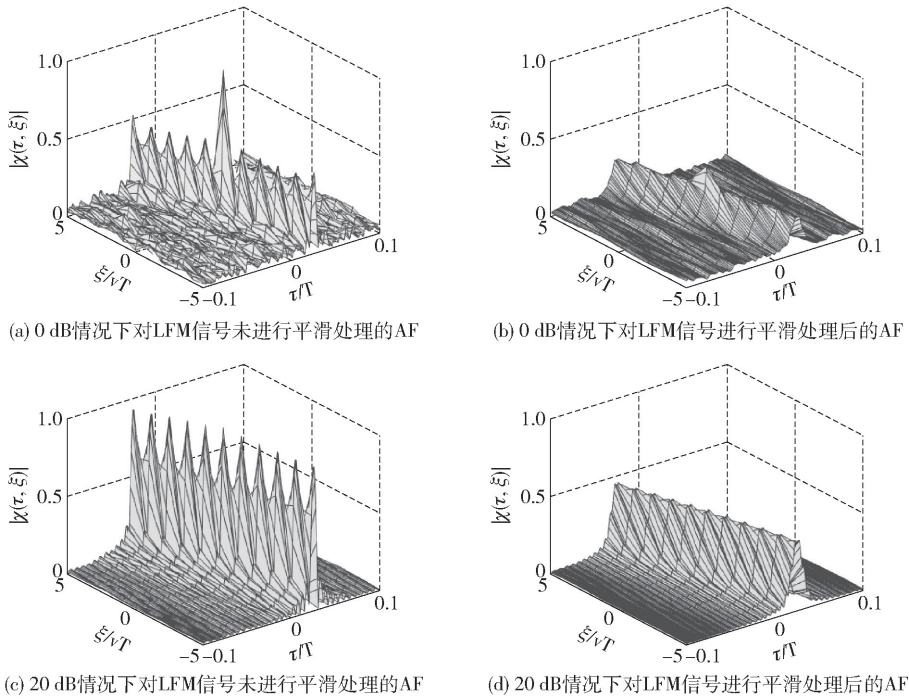


图 1 对 LFM 信号进行平滑处理前后的 AF 对比

1.3 模糊函数正交切片的提取

直接对 AF 进行特征提取复杂度太高. 从三维空间观察到 AF 具有对称特性, 只需研究辐射源信号 AF 的任意一个对称分布, 即可根据对称性得到全平面的分布, 这极大地减少了计算量和复杂度. 因此, 考虑到 AF 的原点能量最大特性, 可选取 AF

的正交切片作为辐射源进一步的特征提取对象, 正交切片由 AF 时延零点和频移零点的切片组成. 图 2 所示为 20 dB 下常规 (CON, convention)、LFM、二相编码 (BPSK, binary phase shift keying)、四相编码 (QPSK, quadrature phase shift keying)、M 伪随机序列 (M-SEQ, M-sequence) 和二频编码 (BFSK, binary

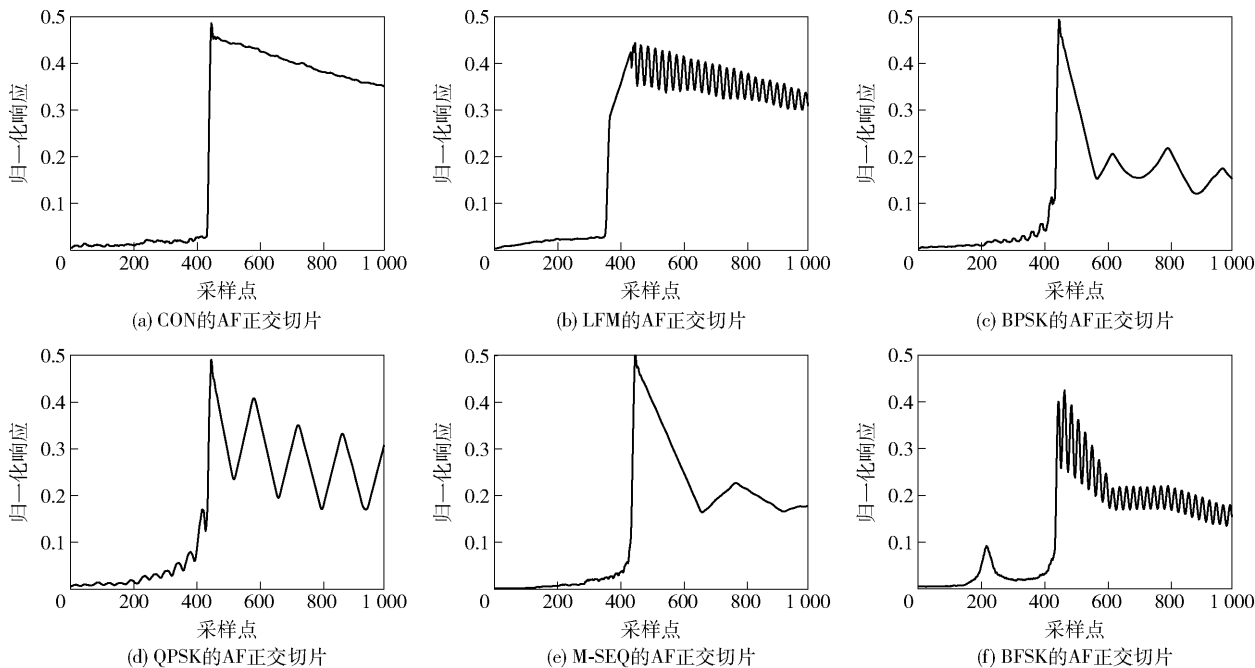


图 2 6 类典型辐射源信号的 AF 正交切片

frequency shift keying)6 类典型雷达信号的 AF 正交切片,采样点  $n$  为 1 024.

## 2 多学习单元 CNN

CNN 是一种以卷积运算为代表的前馈神经网络,其结构主要包括输入层、卷积层、池化层、全连接

层及输出层,如图 3 所示.

### 2.1 输入层

二维 CNN 用以处理对应的 AFOS 二维图像,并且对输入数据进行预处理,有助于提升 CNN 的学习效率,因此采用了高斯平滑的方法对辐射源信号的 AF 进行降噪处理.

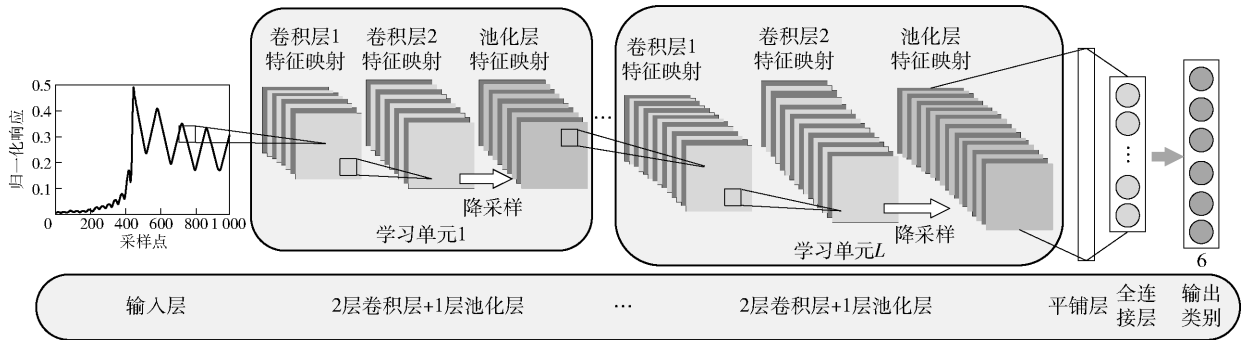


图 3 多学习单元的 CNN 结构

### 2.2 卷积层

选取合适的卷积核,提取不同辐射源信号的 AFOS 数据特征,获得特征映射并保留图像的空间信息. 为了提升网络的学习速度,在卷积层后加入批量归一化层,使网络的学习性能更稳定,同时隐藏层的激活函数为线性整流函数 (ReLU, rectified linear unit),能有效解决网络训练时的梯度消失和训练速度问题.

### 2.3 池化层

池化过程能保留 AFOS 的主要模糊能量特征,并减少下一层的参数和计算量,提升鲁棒性. 通过对上一层提取的特征映射进行最大池化进一步降采样.

### 2.4 输出层

将平铺后的 AFOS 卷积特征送入全连接层,并通过激活函数进行信号分类识别. 考虑到雷达辐射源信号识别属于多分类问题,采用 softmax 分类器作为输出层的激活函数,输出的节点数为识别类别数.

通常,合理增加网络的层数能提升 AFOS 数据特征的表征能力,提取其更深层且泛在的模糊能量特征. 为了提高卷积层对 AFOS 的特征提取和映射能力,将 2 层卷积层和 1 层池化层定义为 1 个学习单元,进一步研究不同学习单元 CNN 对于 AFOS 模糊能量特征的适应性和识别效果.

## 3 基于多学习单元 CNN 的雷达辐射源信号识别算法

算法 1 基于多学习单元 CNN 的识别算法

```

1 初始化变量
2  $E$ :待识别的辐射源
3  $P$ :每个辐射源产生的信号个数
4  $S$ :信噪比
5  $n$ :信号长度
6  $N$ :信号重采样长度
7 for all  $E$  do
8   for all  $S$  do
9     for all  $P$  do
10      获取离散信号  $s(n)$ 
11      依据有理式  $N/n$  将信号  $s(n)$  重采样点数设为  $N$  点
12      由式(1)计算得到信号的 AF
13      构建  $M = 5, \sigma = 1$  的高斯掩膜对 AF 进行平滑处理
14      采用 1.3 节方法提取信号的 AF 正交切片
15      保存 AF 正交切片
16    end for
17  end for
18 end for
19 构建多学习单元 CNN 对 AF 正交切片分类识别
20 统计识别准确率和识别时间
    
```



4 实验与结果分析

采用 CON, LFM, BPSK, QPSK, M-SEQ, BFSK 六种典型信号进行识别仿真实验. 其中, LFM 的带宽为 10 MHz, BPSK 和 BFSK 均采用 13 位 Barker 码, QPSK 采用 16 位 Frank 码, M-SEQ 生成多项式为 1011100. 所有信号的脉宽均为 10  $\mu$ s, 除 BFSK 的 2 个频点分别取 2 MHz 和 10 MHz 外, 其余信号的载频为 10 MHz. 在信噪比 (SNR, signal to noise ratio) 为 0 ~ 20 dB 时, 每类信号每隔 2 dB 生成 20 个信号样本, 共有 1 320 个信号样本可作为训练集. 根据实验方案的具体需求, 每个 SNR 下生成 600 个样本测试集. 实验所用的计算机为联想启天 M400-N000, CPU 为 3.6 GHz, 内存为 8 GB, 仿真平台为 Matlab R2019a.

4.1 多学习单元 CNN 参数和结构优化

下面将对构建的多学习单元 CNN 中的学习率、卷积核大小以及学习单元的选取依据进行讨论.

1) 动态学习率与固定学习率的性能对比

采用指数衰减学习率并结合 Adam 算法进行优化, 初始学习率设为 0.01, 每经过 10 轮训练次数乘一个衰减系数 0.5, 实验选取 SNR 为 -4 dB 时的数据集, 图 4 所示为 2 种学习率在测试集上的识别精度与损失值的对比, 统计结果如表 1 所示.


表 1 不同学习率的评价指标对比

方案	识别准确率/%	损失值	标准差
固定学习率	92.67	0.227 5	0.020
动态衰减学习率	98.62	0.060 8	0.007


从图 4 来看, 相较于固定学习率, 采用动态衰减学习率的网络后期收敛误差更小, 收敛更为平稳. 由表 1 的统计结果来看, 在动态衰减学习率情况下, 网络的识别精度相较于固定学习率提高了 6% 左右, 且损失值下降大约 0.166 7, 达到了较满意的结果. 可见, 动态衰减的方式能更有效地减少误差, 网络能更稳定地收敛.

2) 图像尺寸与卷积核大小的相关性比较

为考察 AFOS 图像大小与卷积核大小的相关性, 采用  $32 \times 32 \times 3$ 、 $64 \times 64 \times 3$  及  $144 \times 144 \times 3$  三种尺寸的图像, 分别在卷积核大小为  $3 \times 3$ 、 $5 \times 5$  及  $7 \times 7$  下进行实验, 批样本统一为 64, 实验选取 SNR 为 -4 dB 环境下的数据集, 实验结果如表 2、表 3 所示.



(a) 不同学习率对网络识别率的影响



(b) 不同学习率对网络损失值的影响

图 4 固定学习率与动态衰减学习率的性能对比

表 2 不同尺寸的图像在不同卷积核的信号识别精度 %

图像尺寸	卷积核大小		
	3 × 3	5 × 5	7 × 7
32 × 32 × 3	93.50	93.88	90.67
64 × 64 × 3	95.66	98.62	98.58
144 × 144 × 3	95.88	97.67	97.83

表 3 不同尺寸的图像在不同卷积核的损失值

图像尺寸	卷积核大小		
	3 × 3	5 × 5	7 × 7
32 × 32 × 3	0.126 6	0.105 0	0.222 6
64 × 64 × 3	0.080 6	0.060 8	0.071 5
144 × 144 × 3	0.080 3	0.079 6	0.068 8

由表 2 和表 3 所示的实验结果可知,  $32 \times 32 \times 3$  大小的正交切片在 3 种卷积核的识别效果明显低于其他 2 种尺寸的正交切片, 因为图像过小其所包含的信息也就越少, 网络学习的性能无法得到保障. 而  $64 \times 64 \times 3$  和  $144 \times 144 \times 3$  大小的正交切片的识别精度和损失都较好, 其中  $64 \times 64 \times 3$

在  $5 \times 5$  卷积核的效果最优。因为  $144 \times 144 \times 3$  大小的正交切片保留的信号信息更多,但同时夹杂的噪声也更多,在网络训练时会把部分噪声当作信号信息进行学习。同时,除了识别准确率以外,辐射源信号识别性能的另一个重要指标就是识别时间。虽然  $144 \times 144 \times 3$  的正交切片包含的信息更多,但网络训练和识别的耗时也更多。综上分析,在保证识别准确率的条件下, $64 \times 64 \times 3$  的正交切片和  $5 \times 5$  的卷积核能更好地满足辐射源信号识别时效性的要求。

表 4 3 种特征在不同学习单元下的识别结果

特征表示	学习单元数	6 类辐射源信号的识别率/%						特征提取与识别平均耗时/s
		CON	LFM	BPSK	QPSK	M-SEQ	BFSK	
双谱	1	62. 67	64. 50	62. 83	61. 98	57. 50	60. 86	35. 09
	2	71. 50	72. 83	70. 20	70. 50	67. 26	69. 74	88. 76
	3	80. 67	78. 98	80. 33	79. 67	72. 83	77. 83	168. 33
	5	80. 88	78. 96	80. 50	79. 88	72. 85	77. 67	654. 03
AF 主脊	1	73. 50	74. 69	72. 00	73. 36	68. 89	71. 30	63. 98
	2	80. 33	80. 98	76. 67	82. 28	78. 33	77. 96	196. 63
	3	86. 67	85. 83	86. 16	87. 83	83. 68	87. 67	346. 02
	5	86. 50	85. 88	86. 20	87. 85	83. 66	87. 65	1 302. 09
AF 正交切片	1	79. 67	80. 66	77. 73	80. 33	75. 40	78. 68	38. 25
	2	82. 50	83. 67	80. 50	85. 67	80. 66	81. 33	103. 98
	3	88. 68	87. 62	87. 83	89. 90	85. 88	87. 90	196. 08
	5	89. 83	88. 00	87. 88	89. 66	84. 96	87. 50	779. 25




图 5 3 种特征的识别率

从表 4 和图 5 的结果可见,3 种辐射源特征都具有良好的噪声抑制能力,且学习单元数  $L = 3$  与  $L = 5$  时的识别精度相差不大,甚至有个别信号出现了识别率略微下降的现象。这是因为当单元数达到一定值时,容易把正交切片中的噪声也当成信号特

3) 不同学习单元对信号识别率的影响

为验证 AF 正交切片特征的优势,实验中分别提取了双谱特征<sup>[9]</sup>、AF 主脊<sup>[7]</sup>及 AF 正交切片 3 种特征作为多学习单元 CNN 的输入,通过 Matlab 的计时函数 tic 和 toc 统计特征提取和识别耗时,以探究不同学习单元 CNN 下的辐射源信号识别效果。表 4 给出了 SNR 为  $-6$  dB 时 6 类辐射源信号在不同学习单元下的识别结果。此外,为考察系统的噪声鲁棒性,分别在 3 种特征数据中加入了不同 SNR 的噪声,实验结果如图 5 所示。

征提取出来,影响了识别准确率。双谱特征的整体准确率明显低于 AF 主脊和 AF 正交切片,主要原因是双谱的相位噪声过大。而 AF 主脊和 AF 正交切片的噪声鲁棒性较强,具有更好的识别效果。但从特征提取和识别平均耗时的角度来看,双谱特征经多学习单元 CNN 特征提取和识别的时间最短,在 3 个学习单元时的识别耗时为 2 min 48 s 左右;其次是 AF 正交切片特征,在  $L = 3$  时的耗时大致为 3 min 16 s,而 AF 主脊的提取过程需要进行 1 800 次主脊搜索,计算量较大,CNN 提取特征的耗时也比另外 2 种特征长,大约为 6 min 46 s。综合考虑识别率和耗时两方面的实验结果,CNN 的学习单元数设为 3。

4.2 与人工特征提取性能的比较

实验选取双谱特征<sup>[9]</sup>、AF 三维特征<sup>[3]</sup>以及 AF 极坐标域特征<sup>[10]</sup>3 种人工方法进行对比,结果如图 6 所示。




图 6 深度学习与人工特征提取的对比

从图 6 可知,双谱特征<sup>[9]</sup>是提取信号的相位噪声特性,因而在低 SNR 情况下的抗噪性能不强. 普运伟等<sup>[3]</sup>从地貌学角度提取了信号 AF 的三维特征,分选成功率在 -2 dB 时只有 79%,因为 AF 地貌特征在 SNR 较低时易受噪声干扰,所提取特征的信息不完备. 普运伟等<sup>[10]</sup>提出了坐标转换的思路,在能量不损失的情况下提取了均面积、致密度等特征,分选成功率大幅提升. 而正交切片特征在低 SNR 环境下,抗噪性能较强,识别效果优于以上 3 种人工方法. 综上所述,人工提取方法难以获得信号更深层且稳定的特征,因此受噪声影响较大. 深度学习虽然需要先验信息,但训练并提取特征的抗噪性能更强.

4.3 与其他深度学习方法的比较

为探究深度学习算法的有效性,构建了集成学习 (EL, ensemble learning)<sup>[11]</sup>、栈式自编码器 (SAE, stacked auto-encoders)<sup>[12]</sup> 以及深度信念网络 (DBN, deep belief network)<sup>[13]</sup> 3 种深度结构,与多学习单元 CNN 进行对比实验的结果如图 7 所示.




图 7 多学习单元 CNN 与其他深度学习方法的对比

由图 7 可见,当 SNR 大于 2 dB 时,4 种方法的

识别效果都较理想,但当 SNR 更低时,EL,SAE 和 DBN 三种方法的抗噪性能不佳,明显低于所提方法. 其中,集成学习的方法采用多个分类器对提取的 AFOS 特征进行分类,由于 BPSK 和 M-SEQ 信号的 AFOS 具有一定相似性,多分类器容易混淆这 2 种信号. SAE 模型在 SNR 为 0 时的识别率虽能达到 92.50%,但在更低 SNR 下的识别效果仍有待提升. 因为 DBN 对幅值较低的 AF 能量信息学习过拟合,并且这部分能量信息易受噪声的干扰,所以该方法的识别准确率在 SNR 为 0 时下降结果较明显. 分析上述结论,多学习单元 CNN 算法模型在低 SNR 下仍能提取到信号的本质特征,相比其他 3 种深度学习模型具备更强的抗噪性能.

4.4 与其他卷积算法网络的比较

为考察不同 CNN 对 AFOS 的分类识别性能,采用现有的 VGG16 和 ResNet50 两种深度卷积网络,与多学习单元 CNN 进行实验对比,其中 VGG16 与 ResNet50 的实验环境为 Python 3.5.6 下的 TensorFlow 框架,块大小为 64,采用同样的动态衰减学习率,初始学习率为 0.001,迭代次数为 150,不同 SNR 下的实验结果如表 5 所示.

表 5 3 种卷积网络的识别性能比较

网络结构	动态 SNR 下的信号识别率/%					平均识别 耗时/s
	-6/dB	-4/dB	-2/dB	0	2/dB	
VGG16	87.68	96.83	98.83	99.67	100	6 180.30
ResNet50	91.50	99.40	100.00	100.00	100	9 510.86
多学习单元 CNN	88.50	98.62	99.86	99.98	100	188.19

从表 5 所示的实验结果来看,VGG16 结构的识别效果要稍低于 ResNet50 和多学习单元 CNN 的效果,对于小样本条件来讲,13 层的卷积层深度过深,若不增加训练样本,易出现训练退化现象,且识别耗时也比较长,平均每个 SNR 下的识别耗时大约为 1 h 43 min. 而 ResNet50 结构在低 SNR 下的识别率提升较大,因为残差跳连能很好地避免网络训练梯度消失. 但从耗时的角度来看,ResNet50 结构的层数最多,训练和识别耗时较大,每个 SNR 下的识别耗时在 2 h 36 min 左右. 而多学习单元 CNN 在识别精度和识别耗时两方面都能达到较好的效果,每个 SNR 下的识别耗时只需要约 3 min 8 s,更适合于小样本条件. 综合以上分析,VGG16 和 ResNet50 网络结构的识别效果都比较好,但是难以解决辐射源信

号识别耗时长的问題,而多学习单元 CNN 在保证识别准确率的前提下,识别耗时更小,更符合实际环境下对时效性的要求。

#### 4.5 算法复杂度分析

复杂度的计算与分析是辐射源信号识别方法的重要指标<sup>[14-16]</sup>。所提方法的问题规模依赖于信号的重采样点数,所以可通过算法对重采样点数的频度和计算量进行分析。

根据文献[9]中的算法计算双谱特征,第1步是提取双谱的幅度谱,需计算  $K$  (数据分段数) 次快速傅里叶变换(FFT, fast Fourier transform), 其中1次FFT的复杂度是  $O(N \lg N)$ , 则第1步的算法复杂度为  $O(K N \lg N)$ 。第2步是计算幅度谱特征截面的分形维数,包括盒维数和信息维数,其复杂度为  $O(2N)$ , 因此双谱特征的复杂度为  $O(K N \lg N + 2N)$ 。

文献[17]中的算法过程是对 Chen 等<sup>[9]</sup>提出特征的补充和改进,通过 Choi-Williams 分布提取了分形维数,取代了双谱,然后提取了频谱的奇异值熵作为分选特征,与分形维数组成三维特征向量。其中奇异值分解为时频图像矩阵的乘法计算过程,复杂度为  $O(N^3)$ 。频谱和 Choi-Williams 变换可通过 FFT 得到,所以此方法的算法复杂度为  $O(N^3 + 2 N \lg N + 2N)$ 。

提取 AF 主脊 AFMR 特征<sup>[7]</sup>的第1步需通过分数自相关计算任意角度的 AF 值。而1次分数自相关计算需进行1次傅里叶反变换[复杂度为  $O(N \lg N)$ ] 和1次  $1+P$  阶的分数 FFT,由文献[18]可知,快速分数 FFT 的复杂度为  $O(9N \lg N)$ 。此外,需要在  $[-\pi/2, \pi/2]$  区间内对 AFMR 进行最大能量切面搜索,当搜索精度为 0.1° 时需搜索 1 800 次,因此 AFMR 特征的复杂度为  $O(18\,000N \lg N)$ 。

由于 AF 正交切片特征的提取面向的是网格采样的离散 AF 值,故可通过 FFT 来计算 AF,此过程的复杂度为  $O(N \lg N)$ 。高斯平滑阶段,首先对 AF 按照网格点按行依次平滑,再对中间结果按列逐渐平滑,其复杂度为  $O(2N^2)$ 。因此,AF 正交切片的算法复杂度为  $O(N \lg N + 2N^2)$ 。

综上所述,从算法阶数的角度而言,奇异值熵和分形维数特征<sup>[17]</sup>的复杂度阶数最高,其次为笔者所提的方法。文献[7,9]方法的复杂度均为  $O(N \lg N)$  阶,但常系数大有不同。在实际应用中,  $N$  的取值范围通常为 100 ~ 1 000,考虑到常系数的要求,可对算法的

总计算量( $C$ )进行估算。总计算量的比较结果为  $C_{\text{文献}[9]} < C_{\text{本文特征}} < C_{\text{文献}[17]} < C_{\text{文献}[7]}$ ,这与表4所示的实验结果基本一致。

## 5 结束语

提出了一种结合 AF 正交切片与多学习单元 CNN 对辐射源信号进行识别的新思路,该方法主要有以下优点:首先,AF 正交切片的提取思路避免了提取 AF 三维特征所需的较大计算量和复杂度;其次,从图像处理的角度构建的多学习单元 CNN,较好地反映了 AF 的三维分布特性和走向;最后,仿真实验与算法分析结果表明,正交切片特征包含了更多不同辐射源信号间的差异。

此外,高斯平滑较好地抑制了毛刺和畸变,但是产生了 AF 塌陷问题,因此,为增强更低信噪比环境下辐射源信号的识别能力,需进一步研究更完备的深度学习模型。

#### 参考文献:

- [1] 时羽, 普运伟, 张天飞. 基于优势遗传的模糊函数主脊切面智能搜索方法[J]. 红外与毫米波学报, 2013, 32(1): 80-85.  
Shi Yu, Pu Yunwei, Zhang Tianfei. Intelligently searching the slice of ambiguity function main ridge based on superiority inheritance [J]. Journal of Infrared and Millimeter Waves, 2013, 32(1): 80-85.
- [2] 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.
- [3] 普运伟, 侯文太, 郭媛蒲, 等. 基于模糊函数三维特征的雷达辐射源信号分选方法[J]. 控制与决策, 2019, 34(10): 2178-2184.  
Pu Yunwei, Hou Wentai, Guo Yuanpu, et al. A sorting method of radar emitter signal based on three dimensional feature of ambiguity function [J]. Control and Decision, 2019, 34(10): 2178-2184.
- [4] 刘渭滨, 邹智元, 邢薇薇. 模式分类中的特征融合方法[J]. 北京邮电大学学报, 2017, 40(4): 1-8.  
Liu Weibin, Zou Zhiyuan, Xing Weiwei. Feature fusion methods in pattern classification [J]. Journal of Beijing University of Posts and Telecommunications, 2017, 40(4): 1-8.
- [5] Qu Zhiyu, Hou Chenfan, Hou Changbo, et al. Radar signal intra-pulse modulation recognition based on convolutional neural network and deep Q-learning network [J].



- IEEE Access, 2020, 8: 49125-49136.
- [6] Ding Lida, Wang Shilian, Wang Fanggang, et al. Specific emitter identification via convolutional neural networks [J]. IEEE Communications Letters, 2018, 22(12): 2591-2594.
- [7] 普运伟, 金炜东, 朱明, 等. 雷达辐射源信号模糊函数主脊切面特征提取方法[J]. 红外与毫米波学报, 2008, 27(2): 133-137.
- Pu Yunwei, Jin Weidong, Zhu Ming, et al. Extracting the main ridge slice characteristics of ambiguity function for radar emitter signals [J]. Journal of Infrared and Millimeter Waves, 2008, 27(2): 133-137.
- [8] Wei Xing, Yang Qingxiong, Gong Yihong. Joint contour filtering[J]. International Journal of Computer Vision, 2018, 126(11): 1245-1265.
- [9] Chen Changxiao, He Minghao, Xu Jing, et al. A new method for sorting unknown radar emitter signal[J]. Chinese Journal of Electronics, 2014, 23(3): 499-502.
- [10] 普运伟, 郭媛蒲, 侯文太, 等. 模糊函数主脊切面极坐标域形态特征提取方法[J]. 仪器仪表学报, 2018, 39(10): 1-9.
- Pu Yunwei, Guo Yuanpu, Hou Wentai, et al. Morphological feature extraction based on the polar transformation of the slice of ambiguity function main ridge [J]. Chinese Journal of Scientific Instrument, 2018, 39(10): 1-9.
- [11] 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.
- Huang Yingkun, Jin Weidong, Yu Zhibin, et al. Radar emitter signal recognition based on deep learning and ensemble learning [J]. Systems Engineering and Electronics, 2018, 40(11): 2420-2425.
- [12] 普运伟, 郭江, 刘涛涛, 等. 基于模糊函数等高线与栈式降噪自编码器的雷达辐射源信号识别[J]. 仪器仪表学报, 2021, 42(1): 207-216.
- Pu Yunwei, Guo Jiang, Liu Taotao, et al. Radar emitter signal recognition based on ambiguity function contour lines and stacked denoising auto-encoders[J]. Chinese Journal of Scientific Instrument, 2021, 42(1): 207-216.
- [13] 石乐义, 李剑蓝, 郭宏彬, 等. 基于深度信念网络的端信息跳变模式自适应策略[J]. 北京邮电大学学报, 2019, 42(3): 64-71.
- Shi Leyi, Li Jianlan, Guo Hongbin, et al. Research on adaptive strategy of end hopping system based on deep belief nets [J]. Journal of Beijing University of Posts and Telecommunications, 2019, 42(3): 64-71.
- [14] Alkhodary M T, Muqaibel A H. Low complexity sparse Bayesian estimation for UWB radar imaging [J]. IET Radar, Sonar & Navigation, 2018, 12(2): 268-275.
- [15] Lu Zheng, Gong Yan. Thoughts on the major challenges of radar emitter recognition technology and countermeasures [J]. National Defence Science & Technology, 2017, 38(2): 24-27.
- [16] Dudczyk J. A method of feature selection in the aspect of specific identification of radar signals[J]. Bulletin of the Polish Academy of Sciences Technical Sciences, 2017, 65(1): 113-119.
- [17] 曲志昱, 毛校洁, 侯长波. 基于奇异值熵和分形维数的雷达信号识别[J]. 系统工程与电子技术, 2018, 40(2): 303-307.
- Qu Zhiyu, Mao Xiaojie, Hou Changbo. Radar signal recognition based on singular value entropy and fractal dimension [J]. Systems Engineering and Electronics, 2018, 40(2): 303-307.
- [18] 赵兴浩, 陶然, 邓兵, 等. 分数阶傅里叶变换的快速计算新方法[J]. 电子学报, 2007, 35(6): 1089-1093.
- Zhao Xinghao, Tao Ran, Deng Bing, et al. New methods for fast computation of fractional Fourier transform [J]. Acta Electronica Sinica, 2007, 35(6): 1089-1093.