

# 控制与决策

Control and Decision

基于模糊函数多域特征融合与集成学习的雷达辐射源信号识别

普运伟, 余永鹏, 姜莹, 田春瑾

引用本文:

普运伟, 余永鹏, 姜莹, 田春瑾. 基于模糊函数多域特征融合与集成学习的雷达辐射源信号识别[J]. *控制与决策*, 2024, 39(1): 39–48.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2022.0703>

---

您可能感兴趣的其他文章

Articles you may be interested in

[人脸性别约束下的深度随机森林表情识别](#)

Facial expression recognition using deep random forest under gender constraints

控制与决策. 2021, 36(7): 1693–1698 <https://doi.org/10.13195/j.kzyjc.2019.1703>

[融合稀疏编码与深度学习的草图特征表示](#)

A feature representation of sketch based on fusion of sparse coding and deep learning

控制与决策. 2021, 36(3): 699–704 <https://doi.org/10.13195/j.kzyjc.2019.0941>

[基于改进卷积神经网络的动力下肢假肢运动意图识别](#)

Intent recognition of power lower-limb prosthesis based on improved convolutional neural network

控制与决策. 2021, 36(12): 3031–3038 <https://doi.org/10.13195/j.kzyjc.2020.0326>

[基于卷积神经网络的云雾遮挡舰船目标识别](#)

Obscured ship target recognition based on convolutional neural network

控制与决策. 2021, 36(3): 661–668 <https://doi.org/10.13195/j.kzyjc.2019.0781>

[基于DST融合多视图模糊推理赋值的三维目标检测](#)

3D object detection based on DST fusion multi-view fuzzy reasoning assignment

控制与决策. 2021, 36(4): 867–875 <https://doi.org/10.13195/j.kzyjc.2019.0434>

# 基于模糊函数多域特征融合与集成学习的 雷达辐射源信号识别

普运伟<sup>1,2†</sup>, 余永鹏<sup>1</sup>, 姜莹<sup>1</sup>, 田春瑾<sup>2</sup>

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

**摘要:** 针对复杂电磁环境下雷达辐射源信号识别方法中存在的抗噪性能差、识别准确率低等问题, 提出一种融合模糊函数多域投影特征的集成深度学习识别方法. 首先, 对信号的模糊函数进行高斯平滑处理, 从多域视角出发选取合适角度对模糊函数进行二维投影以构建特征数据集; 然后, 构建一种基于多域特征融合的两阶段识别分类方法, 使用多个密集连接网络 DenseNet 121 作为初级分类器分别对 3 类特征数据集进行训练学习, 得到初级分类结果; 最后, 通过 Stacking 策略对初级分类结果进行融合学习, 得到最终类别信息. 实验结果表明, 所提出方法在信噪比为 0 dB 时对 6 类典型雷达信号的整体平均识别率均保持在 97.24% 以上, 即使是在 -4 dB 环境中, 识别率也稳定在 87.16% 以上, 验证了所提出方法的有效性和可行性, 具有一定的工程价值.

**关键词:** 雷达辐射源信号; 模糊函数; 信号识别; 多域特征融合; 集成学习

中图分类号: TP974

文献标志码: A

DOI: 10.13195/j.kzyjc.2022.0703

**引用格式:** 普运伟, 余永鹏, 姜莹, 等. 基于模糊函数多域特征融合与集成学习的雷达辐射源信号识别[J]. 控制与决策, 2024, 39(1): 39-48.

## Radar emitter signal recognition based on ambiguity function multi-domain feature fusion and ensemble learning

PU Yun-wei<sup>1,2†</sup>, YU Yong-peng<sup>1</sup>, JIANG Ying<sup>1</sup>, TIAN Chun-jin<sup>2</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:** Aiming at the problems of poor anti-noise performance and low recognition accuracy of the radar emitter signal recognition method in the complex electromagnetic environment. An integrated deep learning recognition method based on multi-domain projection features of ambiguity function is proposed. Firstly, an ambiguity function is processed using a Gaussian operator, and the appropriate angle is selected to carry out two-dimensional projection to build a characteristic data set from the multi-domain perspective. Then, a two-stage recognition and classification method based on multi domain feature fusion is constructed. Multiple dense connected networks DenseNet 121 are used as primary classifiers to train and learn the three kinds of feature data sets respectively, and the primary classification results are obtained. Finally, the results of the primary classification are integrated through the Stacking policy to obtain the final classification result. The experimental results show that the overall average recognition rate of the six types of typical radar signals is above 97.24%, when the signal-to-noise ratio is 0 dB, even in the -4 dB environment, the recognition rate is also stable in 87.16%, which verifies the effectiveness and feasibility of the proposed method, and its certain engineering value.

**Keywords:** radar emitter signal; ambiguity function; signal recognition; multi-domain feature fusion; ensemble learning

## 0 引言

随着现代电子侦察和对抗领域的迅速发展, 雷达辐射源信号 (radar emitter signal, RES) 呈现出了波形复杂、参数捷变、调制多样的特点, 依靠脉冲描述字外

部特征的 RES 识别方法已经难以满足现代战场的实际需求. 因此, 寻求一种能够反映辐射源信号本质的脉内特征学习方法对于实现提升 RES 识别效果具有重要的现实意义.

收稿日期: 2022-04-26; 录用日期: 2022-08-28.

基金项目: 国家自然科学基金项目 (61561028).

†通讯作者. E-mail: puyunwei@126.com.

针对RES脉内特征参数的提取,目前,时频分析法<sup>[1-4]</sup>、高阶谱法<sup>[5-6]</sup>、模糊函数法等以时频域为主要代表的变换域特征提取方法已然成为国内外学者的研究热点.其中,时频分析、高阶谱等分析方法对于不同调制类型的辐射源信号识别效果并不理想,且易受噪声扰动.而模糊函数(ambiguity function, AF)包含了信号丰富的时频信息,其波形能够完整地描述信号的结构信息,可挖掘出信号丰富的细微特征.文献[7]通过对模糊函数主脊(ambiguity function main ridge, AFMR)进行预处理,获得了抗噪性能较好的特征参数.文献[8]从主、侧视角出发,提取AF的三维特征,并取得了不错的识别效果.但是在上述大多数方法中,提取的均是信号某一方面的细微特征.而真实环境中雷达辐射源信号调制复杂、参数多变,单一的信号特征难以充分、准确地表征辐射源信号各方面的内在细微差异,具有一定的局限性.

近年来,随着人工智能技术的快速发展,深度神经网络(deep neural network, DNN)广泛应用于辐射源信号分类识别领域中<sup>[9]</sup>.相较于以往人工特征提取方法,深度神经网络有利于提取辐射源信号更深层的细微特征.文献[10]提取辐射源信号的时频特征,并通过残差神经网络实现雷达信号的有效识别.文献[11]对AFMR进行极坐标变换提取二维特征,并通过卷积神经网络进行特征学习和分类识别,最终达到不错的识别率.文献[12]直接将原始RES输入至深度神经网络,实现辐射源信号识别,具有较强的整体性.在以上方法中,为了提高识别精度,通常采用单个深度神经网络作为强分类器进行分类识别,而在现代战场环境中样本数量稀缺,若样本量过小,则复杂度和深度较高的单个深度神经网络易出现过拟合现象,导致最后的识别精度受到影响.

针对以上方法存在的问题,文献[13]采用多特征提取的思想,提取能量分布信息、分形特征和双谱特征,并采用支持向量机(support vector machines, SVM)进行识别分类,最终达到不错的识别效果.文献[14]采用多分类组合方法,首先通过主成分分析(PCA)实现特征提取,然后构造 $K$ 邻近、随机森林和神经网络的多分类器融合模型进行分类识别,识别精度得到了较大提升.文献[15]构建了一种基于深度学习和集成学习识别框架,该框架将特征提取和分类器设计分为两部分,结果表明,结合这两种机器学习的方法有助于提高辐射源信号的识别准确率.因此,从信息融合的角度出发,展开多域联合特征提取,充分挖掘信号内在细微特征,并与集成深度学习识别方法相结合

不失为一种更有效和更可靠的方案.

基于以上讨论,本文提出一种融合模糊函数多域投影特征的集成深度学习识别方法.针对单一信号特征的局限性,设计基于模糊函数的多域特征提取方法,从模糊函数的不同域充分挖掘信号内在细微特征.此外,针对样本量不足的情况,本文采用基于多域特征融合的两阶段识别方法,为了充分利用深度神经网络在图像处理方面的优势,首先利用多个深度神经网络分别对不同的特征数据集进行训练学习,得到以概率形式表征的特征向量;然后采用集成学习方法融合特征向量,以获得最终的识别结果.实验结果表明,该方法在各种信噪比环境下均取得了良好的识别效果.

## 1 基于模糊函数的多域变换特征提取方法

### 1.1 模糊函数

窄带雷达辐射源信号是一种非平稳信号,可用 $s(t)$ 表示, $s(t)$ 的AF定义为

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

其中: $s^*(t)$ 为 $s(t)$ 的共轭, $\tau$ 为时延, $\xi$ 为多普勒频移.式(1)表明,AF实质为 $s(t)$ 匹配滤波器对给定延迟-多普勒信号的响应,是信号在时域与频域上的联合二维时频表示,能够较好地反映信号内在结构特性.

### 1.2 模糊函数平滑处理

AF唯一性定理指出,信号模糊体积的分配完全由信号本身所决定,因此不同调制类型的辐射源信号所包含的AF也不同,这为从信号AF的角度获取信号本身的特征参数提供了理论基础.

需要注意的是,在真实环境中雷达信号往往伴随着较强噪声,这会使得AF增加许多畸变和毛刺,从而大幅增加RES识别的难度.考虑到高斯滤波器能够较好地处理毛刺现象<sup>[16]</sup>,本文采用尺寸为 $5 \times 5$ ,标准差为1的高斯掩膜对信号的AF进行平滑降噪处理.平滑后的AF为

$$\bar{\chi}(i, j) = \frac{\sum w(m, n) \times \chi(i, j)}{\sum \omega(m, n)}. \quad (2)$$

其中: $(i, j)$ 为任意网格点; $w$ 表示网格点周围尺寸为 $M \times M$ 的掩膜; $w(m, n)$ 为掩膜范围内权重因子,定义为

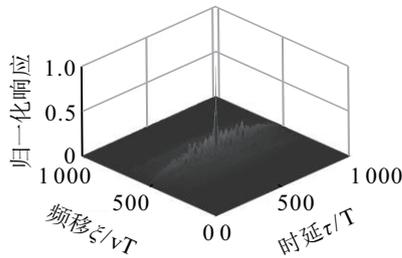
$$w(m, n) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left[-\frac{(m^2 - n^2)}{2\sigma^2}\right]. \quad (3)$$

其中: $m, n$ 为掩膜中权重因子所在位置坐标, $\sigma$ 为标准差.

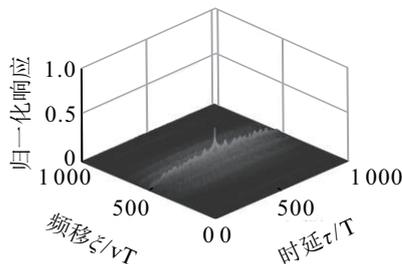
高斯掩膜尺寸 $M$ 和标准差 $\sigma$ 是平滑阶段的2个

关键参数, 高斯掩膜是对连续高斯函数的离散近似, 掩膜越大, 近似范围越大, 卷积运算的乘法次数越多, 则算法的复杂度越高. 常用掩膜尺寸为 $3 \times 3$ 、 $5 \times 5$ 、 $7 \times 7$ . 标准差 $\sigma$ 为数据离散程度, 表现为图像的平滑效果,  $\sigma$ 的值越大, 图像平滑效果越明显, 但是图像细微信息损失也越多, 因此 $\sigma$ 的大小取决于问题背景. 在本文的研究中, 参数设计原则既要满足不同SNR下同类信号的平滑效果接近, 同时又要求算法的复杂度不能过高. 综合考虑, 采用 $M=5$ ,  $\sigma=1$ 的高斯掩膜较为合适.

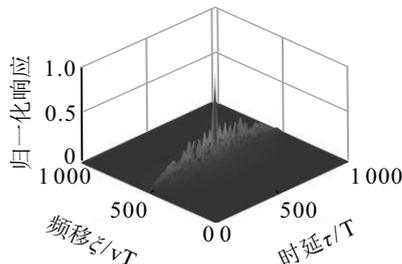
为验证参数设计的合理性, 分别在0 dB和10 dB情况下对二相编码(BPSK)信号的AF进行平滑处理, 结果如图1所示. 由图1(a)和图1(c)可见, 在强噪声的干扰下, 信号AF的失真较为严重, 这使得RES识别



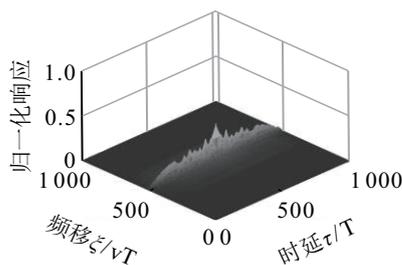
(a) SNR=0 dB时 BPSK 信号未经过平滑处理的AF



(b) SNR=0 dB时 BPSK 信号经过平滑处理的AF



(c) SNR=10 dB时 BPSK 信号未经过平滑处理的AF



(d) SNR=10 dB时 BPSK 信号经过平滑处理的AF

图1 0 dB和10 dB下BPSK信号的AF平滑处理前后对比

的难度大幅增加, 但是经过 $\sigma=1$ 的平滑处理后, 毛刺明显减少, 且不同SNR下同类信号的AF形状变得接近. 实验验证所设计的掩膜参数满足研究要求.

### 1.3 基于多域变换投影的特征提取

从三维空间观察到AF有着与山峰地貌类似的结构特点, 直接进行特征提取计算量和复杂度较高, 因此为能够较为完整地挖掘出AF的三维特征, 本文提出一种多域视角变换投影方法, 选取合适投影视角对AF进行投影, 使其表征为二维特征图像.

从AF时延域观察, 能够得到AF三维图中“岭”的走势, 岭的形状层峦迭嶂, 具有独特的轮廓、纹理分布特性. 因此选取逆时针旋转角度和垂直升降角度均为 $0^\circ$ 的投影视角将AF三维图像投影于XZ平面. 可见, 时延域包含了AFMR切面以及相同时延条件下模糊能量的分布.

与AF时延域相比, AF多普勒频域刻画了AF中“峰”的特点, 峰的形状高耸孤立, 包含较高的模糊能量, 鲁棒性较强, 适合作为特征提取的对象, 因此选用逆时针旋转角度 $90^\circ$ 、垂直升降角度 $0^\circ$ 的投影视角将AF三维图像投影于YZ平面.

信号AF反映了信号在时延 $\tau$ 与频移 $\xi$ 平面上的联合时频表示, 时延-多普勒频域清晰地描述了信号AF频率随时间变换的关系, 且具有一定的集中性, 能够体现AF中心主瓣形状, 故取逆时针旋转角度 $0^\circ$ 、垂直升降角度 $90^\circ$ 的投影视角将AF三维图像投影于XY平面.

图2为CON、LFM、BPSK、BFSK、QPSK、M-SEQ六类经典辐射源信号经多域投影变换后的AF二维图像, 从左至右依次为时延-多普勒频域投影、时延域投影、多普勒频域投影. 其具体流程如算法1所示.

#### 算法1 模糊函数多域视图特征提取.

##### 1. 初始化变量

Emitter: 待分选辐射源;

Num: 每个辐射源产生的信号数;

SNR: 信噪比;

$n$ : 信号长度;

$N$ : 信号重采样长度;

##### 2. for each Emitter.

##### 3. for each SNR.

##### 4. for each Num.

##### 5. 获得离散信号 $s(n)$ .

6. 根据有理式 $N/n$ 对信号 $s(n)$ 重采样, 使得信号保持相同长度, 取 $N=1024$ .

7. 根据信号长度产生时频域网格采样点, 计算对应点的AF归一化响应, 绘制AF三维图.

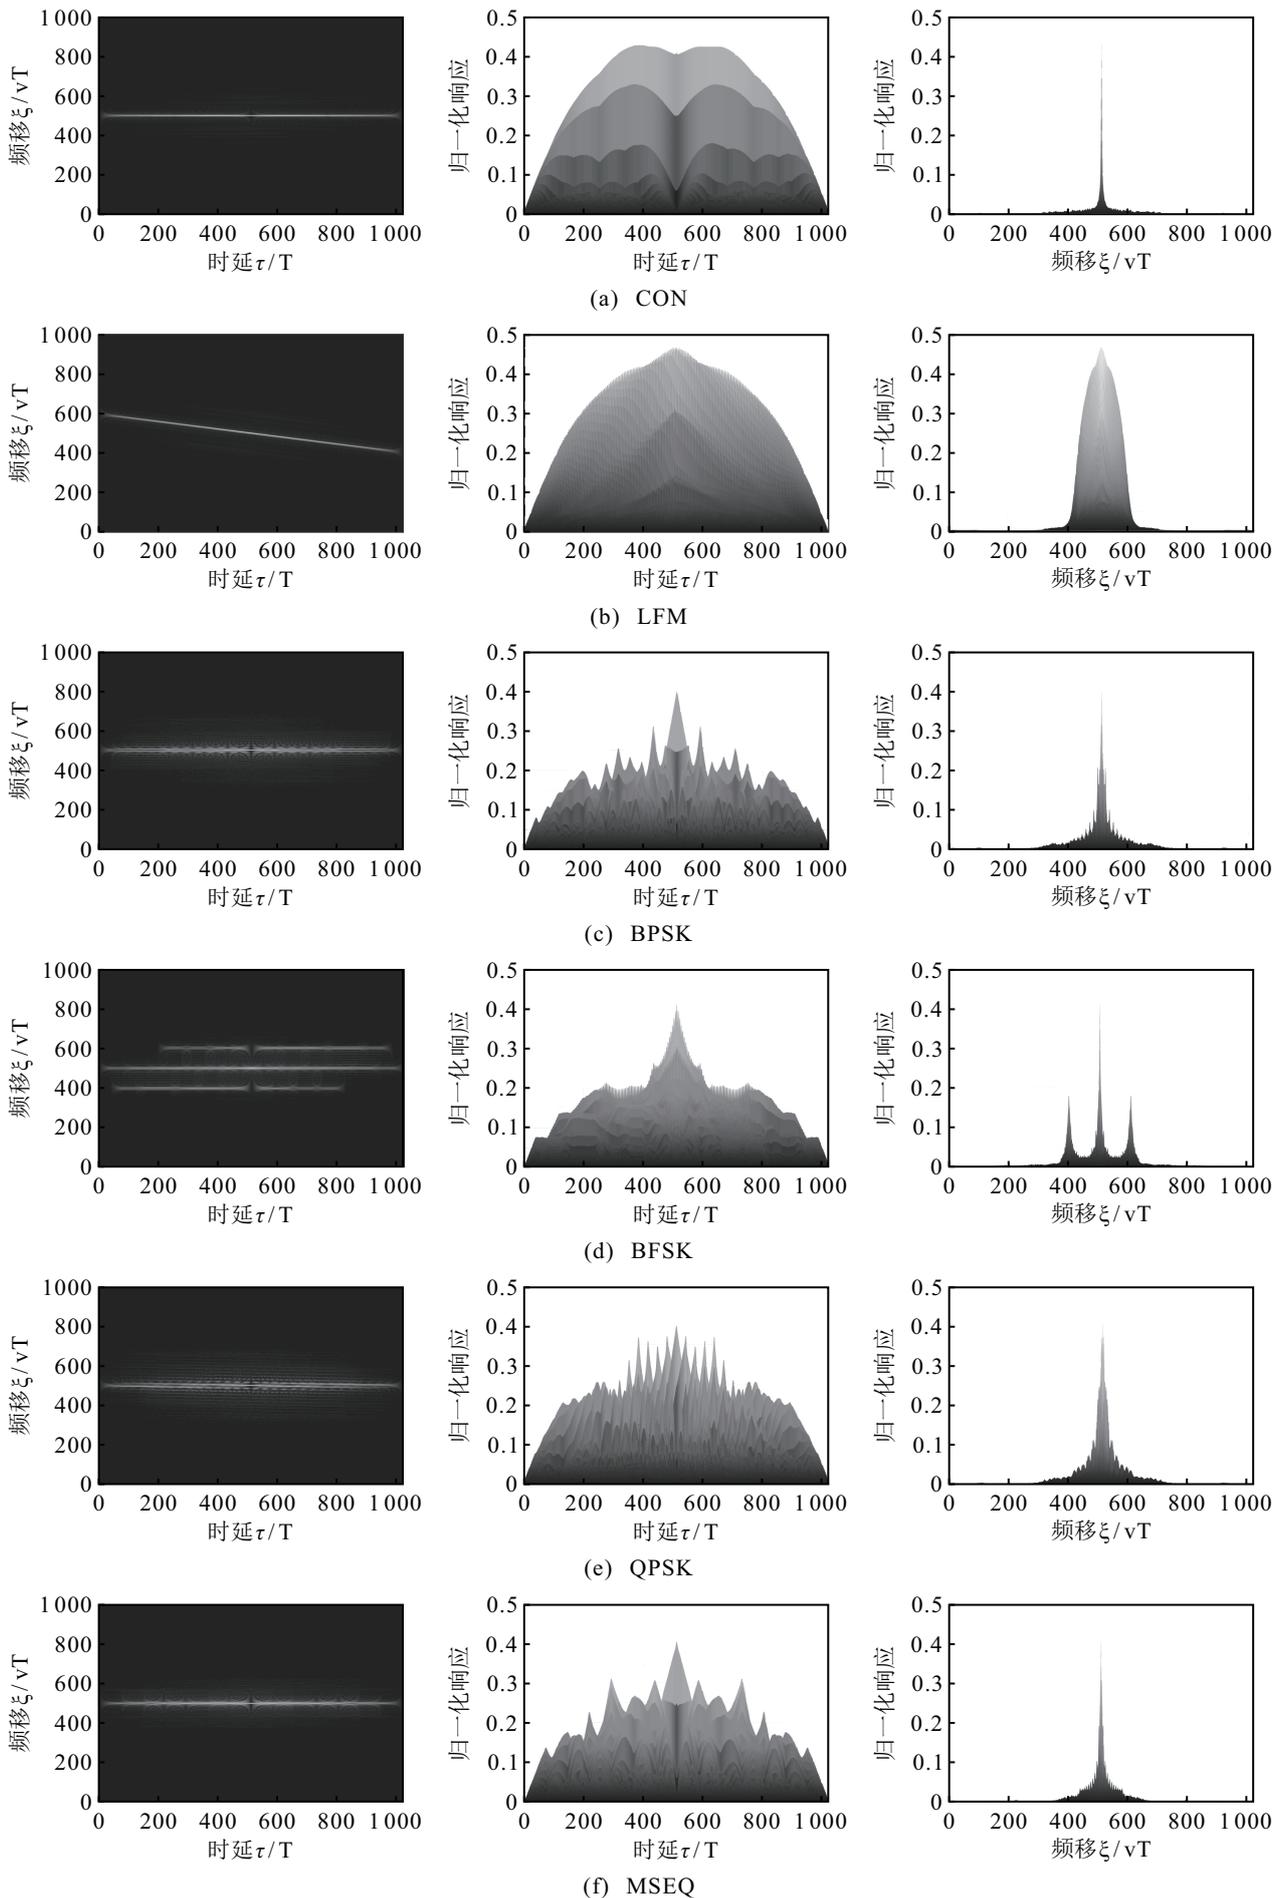


图2 6类经典辐射源信号的AF多域投影二维图

8. 采用高斯平滑对AF进行处理.
  9. 分别选取不同合适视角对AF进行变换投影, 得到AF二维图像数据集.
  10. end.
  11. end.
  12. end.
- 算法结束.

由算法1可知, 每个类别的雷达信号生成3个不同的AF二维图像数据集, 每个数据集有 $m$ 张图像, 共 $n$ 个信号类别.

## 2 多域特征融合两阶段分类识别

基于神经网络在图像处理方面的优势, 可通过其对上述方法得到的AF二维图像进行分类识别. 但是, 原始图像的维数太大, 所需的计算工程量较高, 因此需要对输入图像进行预处理, 同时考虑到过多的预处理可能会丢失图像细微信息, 所以本文仅采取灰度化、归一化等方法进行预处理以便完整保留AF内在特征. 在分类识别阶段, 对预处理后的特征数据集首先进行初级分类识别, 然后将多域特征的初级识别结果进行次级融合, 以提升雷达辐射源信号的识别精度. 具体流程如算法2所示.

### 算法2 模型训练和分类识别.

模型训练.

输入: AF二维图像数据集, 共3个;

输出: 每张图像的预测结果.

1. 将AF时延域图像数据集输入密集连接网络1进行训练, 输出初始分类结果 $P_\tau$ , 并保存模型参数.
2. 将AF多普勒域图像数据集输入密集连接网络2进行训练, 输出初始分类结果 $P_\xi$ , 并保存模型参数.
3. 将AF时延-多普勒域图像数据集输入密集连接网络3进行训练, 输出初始分类结果 $P_{\tau-\xi}$ , 并保存模型参数.
4. 将 $P_\tau$ 、 $P_\xi$ 和 $P_{\tau-\xi}$ 输入次级分类器进行训练学

习, 并保存模型参数.

分类识别.

输入: 待识别信号的特征图像, 每个信号有3张特征图像;

输出: 待识别信号的最终分类结果 $P_{\text{final}}$ .

1. 将待识别信号的AF时延域特征图像输入密集连接网络1, 输出初始预测结果 $P_\tau$ .
2. 将待识别信号的AF多普勒域特征图像输入密集连接网络2, 输出初始预测结果 $P_\xi$ .
3. 将待识别信号的AF时延-多普勒域特征图像输入密集连接网络3, 输出初始预测结果 $P_{\tau-\xi}$ .
4. 将 $P_\tau$ 、 $P_\xi$ 和 $P_{\tau-\xi}$ 输入次级分类器进行最终识别, 输出最终分类预测结果 $P_{\text{final}}$ .

### 2.1 基于密集连接网络的初级阶段

在初级阶段选用DenseNet 121深度学习模型作为初级分类器, 密集连接网络DenseNet因其对梯度消失的缓解作用以及对特征的高效利用和传播效率被广泛应用于深度学习的研究<sup>[17]</sup>. 样本数量较小时, 直接进行训练会导致过拟合现象, 因此本文选用公开ImageNet数据集预训练模型的权重, 可充分利用网络已有的参数, 使得网络具有较强的适应性. 由于数据集类别具有差异, 在对网络进行训练前需要修改网络结构, 使其与AF二维图像数据集类别对应.

如图3所示, 本文冻结除原全连接层外的各层, 并对原全连接层微调. 在Dense层的最后添加一个输出单元为特征图像size的Linear层, 再连接ReLU层与Dropout层, 提高参数的泛化能力, 防止网络参数对训练数据的重度依赖, 然后连接一个Linear层, 最后采用Softmax作为分类器, 将输出的节点数改为信号的类别数 $n$ 个. 输入训练数据集对全连接层的权重进行微调训练, 训练结束后对模型进行保存. 当进行识别任务时, 网络输出的是各信号的类别概率, 为 $P_i = [p_0, p_1, \dots, p_n]$ . 3个密集连接网络的输出分别为 $P_\tau$ 、 $P_\xi$ 和 $P_{\tau-\xi}$ .

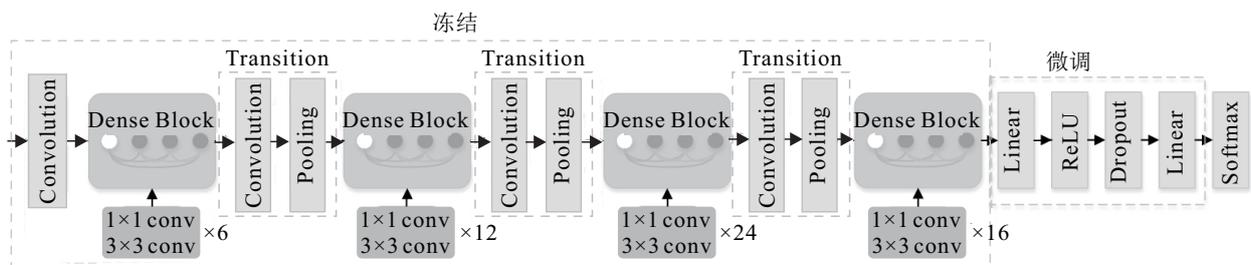


图3 更改后的DenseNet 121网络结构

### 2.2 基于集成融合的次级阶段

次级分类需要将3个神经网络的初级分类结果进行融合, 并完成最终分类. 本文采用集成学习中的

Stacking策略, 可最大化整体模型的分类能力. 同时初级分类使用单一预测模型, 易出现方差过大问题, 因此次级分类器需选择具有较强泛化能力的模型,

从而降低预测误差对结果的影响. 梯度提升决策树 (gradient boosting decision tree, GBDT) 模型具有精度高、对异常值的鲁棒性高等优点, 故选择GBDT模型作为次级分类器. 模型两阶段识别流程如图4所示.

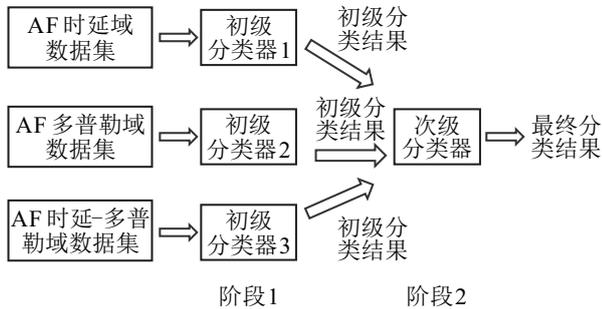


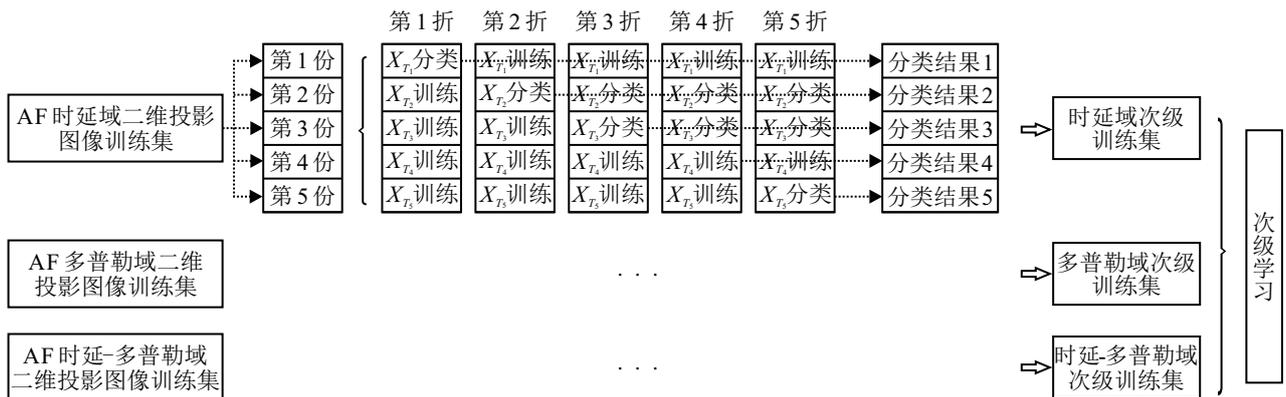
图4 模型两阶段识别流程

### 2.3 训练集和测试集的使用流程

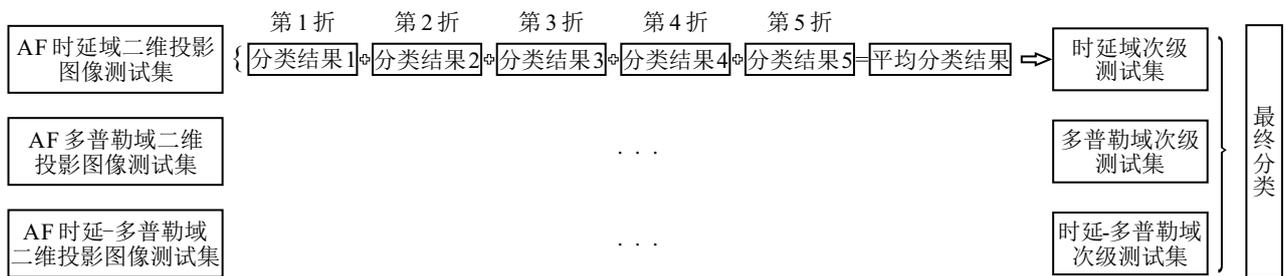
Stacking 方法易出现过拟合现象, 因此采用5折交叉验证方式对每个初级分类器进行训练, 降低过拟合的风险. 具体实现方式为: 首先, 将训练集数据进行5等分, 记为  $X_{T_1}$ 、 $X_{T_2}$ 、 $X_{T_3}$ 、 $X_{T_4}$  和  $X_{T_5}$ ; 然后, 进行

5折交叉验证, 取第1折训练集数据  $X_{D_1} = X_{T_2} \cup X_{T_3} \cup X_{T_4} \cup X_{T_5}$  对一个初级分类器进行训练, 剩余样本  $X_{T_1}$  进行分类识别, 记录分类结果; 同时对测试集所有样本也进行分类识别. 下一折交叉验证重复上述过程, 训练数据为  $X_{D_2} = X_{T_1} \cup X_{T_3} \cup X_{T_4} \cup X_{T_5}$ , 剩余样本  $X_{T_2}$  进行分类识别, 经过5折交叉验证后, 得到该密集连接网络在5组数据上的所有分类结果, 这时测试集数据也进行了5次分类, 最终对分类结果进行均值处理. 每个初级分类器均基于一个完整的图像训练集进行训练, 训练集、测试集的使用流程如图5所示.

数据集中每个样本的分类结果均为  $P_i = [p_0, p_1, \dots, p_n]$ , 将3个密集连接网络对原训练集的初级分类结果进行拼接整合, 得到次级训练集, 原测试集的初级分类结果作为次级测试集. 对于同一个样本, 每个初级分类器均有一个分类结果, 次级分类器对每个初级分类器的分类结果分配权重, 以进行融合取舍, 得到最终分类结果  $P_{final}$ .



(a) 训练集的使用流程



(b) 测试集的使用流程

图5 训练集和测试集的使用流程

## 3 实验结果与分析

### 3.1 实验环境与信号参数设置

通过仿真CON、LFM、BPSK、QPSK、M-SEQ、BFSK 六类常见辐射源信号验证方法的可行性和有效性, 重采样长度  $N = 1024$ . 具体参数设置为: 信号采

样频率  $f_s = 60$  MHz; 脉冲载频  $f_c = 10$  MHz; 脉冲宽度  $PW = 10$  us; 其中LFM信号的带宽为10 MHz, BPSK和BFSK均为13位Baker码; M-SEQ编码为 [1 0 1 1 1 0 0]; QPSK则为16位Frank码. 此外, 除BFSK的2个频点分别取10 MHz和2 MHz外, 其余

信号的载频 $RF = 10\text{ MHz}$ .

实验数据设置为: 在 $\text{SNR} \in (-4, 12)\text{ dB}$ 的条件下, 每类信号每隔 $2\text{ dB}$ 生成 $40$ 个不同初相的信号样本, 共有 $2160$ 个信号作为训练集; 测试集根据实际实验需求, 每个 $\text{SNR}$ 下每类信号各产生 $100$ 个, 共 $600$ 个信号.

实验的信号仿真和处理工作在 $\text{Matlab}$ 环境下完成, 深度学习环境为 $\text{Python 3.6} + \text{Pytorch 1.9}$ .

### 3.2 与人工特征提取方法对比

本节测试整个融合框架模型对 $6$ 类雷达辐射源信号的识别性能, 同时为探究在低 $\text{SNR}$ 情况下所提出方法与人工特征提取方法的性能差异, 实验选取 $\text{AF}$ 三维特征<sup>[8]</sup>、 $\text{DTW}$ 距离特征<sup>[18]</sup>、奇异值熵和分形维数特征<sup>[19]</sup>以及 $\text{AF}$ 极坐标域特征<sup>[20]</sup>4种人工方法进行对比, 结果如图6所示.

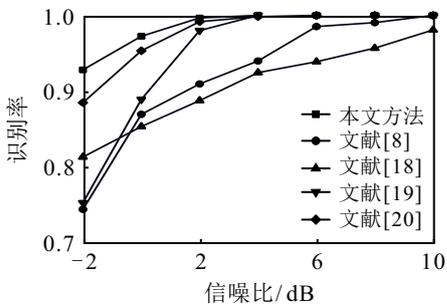


图6 与人工特征提取方法的对比

由图6可见, 文献[18]采用 $\text{DTW}$ 作为样本相似度的度量方法构建 $\text{RES}$ 距离特征, 有着较高的时间复杂度, 且在 $3\text{ dB}$ 时识别率仅为 $91.39\%$ . 文献[8]从地貌学角度提取信号 $\text{AF}$ 的主岭重心、主峰分布半径等三维特征, 在 $-2\text{ dB}$ 时平均分选成功率为 $74.45\%$ , 主要原因为 $\text{AF}$ 在低 $\text{SNR}$ 时易受噪声影响. 文献[19]所提出的奇异值熵和分形维数特征虽然综合了时频域的信息, 但是所提出特征的抗噪性能不强, 在 $-2\text{ dB}$ 时识别准确率仅为 $75.3\%$ . 文献[20]提出了极坐标域转换的思路, 能够在不损失 $\text{AF}$ 能量的情况下, 提取致密度、似圆度等特征, 在低 $\text{SNR}$ 时分选成功率有较大提升, 在 $-2\text{ dB}$ 时能够达到 $88.5\%$ .

综上所述, 人工提取特征的方法在低信噪比环境下难以提取信号深层且更稳定的特征, 整体表现不佳, 而深度学习虽然有监督学习, 需要信号的先验信息, 但其训练并提取的特征能够更完备地表述信号的内在信息, 能够较大幅度上提升信号的识别准确率.

### 3.3 与其他深度学习模型方法对比

为进一步考察所提出方法的有效性, 通过实验对不同深度学习方法进行对比分析. 本文选取文献[15]、文献[21]与文献[22]的3种方法进行比较, 实验

结果如图7所示.

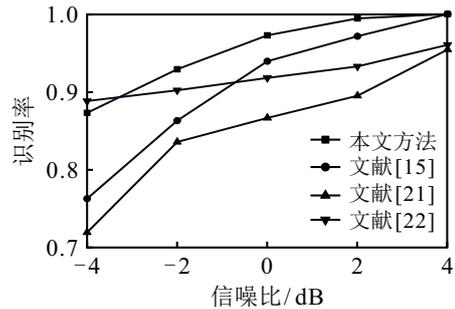


图7 与其他深度学习模型方法对比

由图7可见, 在 $\text{SNR} > 4\text{ dB}$ 时, 4种方法的抗噪性能均较好, 但是在低信噪比环境下, 文献[15]和文献[21]所用方法的识别准确率下降较快. 当信噪比为 $-4\text{ dB}$ 时, 文献[22]所用方法虽然识别率比所提出方法略优, 但是识别准确率提升较慢, 整体性能不如所提出方法. 分析原因, 文献[15]主要在特征提取后所用的分类器方面进行了改变, 但是对识别准确率没有明显的提升. 文献[21]提取盒维数、信息维数、近似熵特征作为识别的三维特征, 输入改进后的反向传播(back propagation, BP)网络进行分类, 所提取的特征在低 $\text{SNR}$ 下易受噪声干扰. 文献[22]使用双谱特征作为网络的输入, 所采用的卷积神经网络虽然对信号的识别具有一定的提升作用, 但是提升的效果不够明显, 整体表现不佳. 分析上述原因, 本文使用基于融合模糊函数多域投影特征的集成深度学习识别方法, 相比于其他3种深度学习模型在整体上有更好的性能表现.

### 3.4 与不同结合策略方法对比

为验证 $\text{Stacking}$ 集成策略下整个融合框架模型的有效性, 本文分别采用多数投票法(majority voting, MV)、加权投票法(weighted voting, WV)作为结合策略的集成方法与 $\text{Stacking}$ 的集成策略进行比较, 结果如表1所示.

表1 不同集成策略的对比

方法	动态SNR下的信号识别率/%			
	-2 dB	0 dB	2 dB	4 dB
MV	89.26	95.08	99.09	100
WV	90.07	95.39	99.25	100
Stacking	92.83	97.24	99.44	100

由表1可见, 虽然随着 $\text{SNR}$ 的逐渐增大, 不同结合策略的集成方法在识别准确率上的差异不断降低, 且在 $\text{SNR}$ 为 $2\text{ dB}$ 时的识别差异不到 $1\%$ , 但是在较低信噪比的情况下, 采用 $\text{Stacking}$ 策略的集成方法明显

优于采用MV和WV作为结合策略的集成方法,这是因为Stacking能够归纳并纠正不同初级分类器的错误预测结果,同时采用5折交叉验证后能够保持较好的泛化能力从而避免过度拟合,进而能够提升整个模型的识别性能。

### 3.5 系统鲁棒性分析

通过不同训练数据量下辐射源信号的总体平均识别率验证系统的鲁棒性。为了使得实验更加充分,采用SNR分别为-4 dB、-2 dB、2 dB三种不同信噪比的环境下进行测试。在每个信噪比下,每个类别的RES测试数据固定为100组,训练数据从100组逐渐增加至600组,步长为100组。实验结果如图8所示。

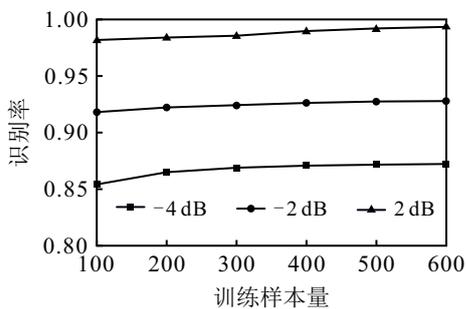


图8 不同训练数据量下RES识别准确率

从实验结果上看,随着训练数据的增加,各信噪比下RES的整体平均识别精度逐渐提高,且信噪比越低,训练样本量对识别精度的影响越明显。观察识别率曲线可发现,当训练样本量超过400组时,3种不同信噪比环境下的RES识别精度提升得较为平缓,基本趋于稳定。在信噪比为-4 dB的环境下,当训练样本量增加到400组后,识别准确率变化较为细微,验证了在低信噪比的情况下,即便样本数量较少,本文系统仍然具有较好的分类性能和良好的鲁棒性。

### 3.6 算法复杂度分析

复杂度的计算和分析是RES识别方法的一个关键性能指标<sup>[23-25]</sup>。为考察本文所提出算法复杂度的运算量,分别采用文献[10]、文献[11]和文献[26]的特征提取方法与所提出算法进行复杂度对比,结果如表2所示。

表2 不同方法的算法复杂度对比

特征提取方法	算法复杂度
文献[10]方法	$O(N^2 \log N + 3N^2)$
文献[11]方法	$O(18\,000N \log N + 7N)$
文献[26]方法	$O((PN + N^2) \log N + N^2)$
本文方法	$O(N \log N + 2N^2 + 3N)$

根据文献[10]的算法步骤,首先对原始信号进行平滑伪Wigner-Ville分布变换,单次的复杂度为

$O(N^2 \log N)$ ;然后对时频图像分别进行开运算、均值滤波和双3次插值法缩放,复杂度为 $O(3N^2)$ ,故文献[10]特征的算法复杂度为 $O(N^2 \log N + 3N^2)$ 。

文献[11]中二维AFMR的提取首先需要利用分数自相关计算任意角度对应的AF值,复杂度为 $O(N \log N)$ 。此外,需要对AFMR进行次数为1800的搜索,因此复杂度为 $O(18\,000N \log N)$ ,之后需对一维AFMR进行极坐标变换,其复杂度为 $O(7N)$ ,所以此方法的复杂度为 $O(18\,000N \log N + 7N)$ 。

文献[26]中的算法首先进行Chirp基分解,在二维搜索过程中变换阶次数为 $P$ ,故Chirp基分解的复杂度为 $O(PN \log N)$ ;然后进行伪Wigner-Ville分布变换,单次的复杂度为 $O(N^2 \log N)$ ;最后计算Zernike矩,复杂度为 $O(N^2)$ 。因此该文特征的特征提取算法复杂度为 $O((PN + N^2) \log N + N^2)$ 。

所提出方法首先计算的是网格采样的离散AF值,可采样FFT进行直接计算,此过程的复杂度为 $O(N \log N)$ 。平滑处理环节,需首先对AF按行逐渐平滑,然后对中间结果按列依次平滑,其复杂度为 $O(2N^2)$ 。变换投影环节,对平滑后的AF采用多域投影,复杂度为 $O(3N)$ ,因此所提出方法的算法复杂度为 $O(N \log N + 2N^2 + 3N)$ 。

综上所述,从算法阶数的角度而言,文献[11]提取的二维AFMR复杂度阶数最低,为 $O(N \log N)$ ,其余包括本文在内的方法复杂度阶数均为 $O(N^2)$ 阶,但是其余项系数有很大差异。在实际应用中,采样点数 $N$ 的取值通常在128~1024范围内,因此可对算法的总计算量 $C$ 进行估算,总计算量的比较结果为 $C_{\text{本文特征}} < C_{\text{文献[26]}} < C_{\text{文献[10]}} < C_{\text{文献[11]}}$ 。算法总计算量的取值范围在 $[10^5, 10^7]$ 区间内,能够很好地适应实时性的需求,满足实际需要。

### 3.7 实测雷达数据实验

为进一步验证所提出方法的实际工程应用价值,采用某雷达外场部分实测数据进行实验。选取5种雷达辐射源产生的各100个样本,共500个样本作为测试数据,识别结果如表3所示。实测数据参数设置如表4所示。

表3 实测雷达数据识别结果

雷达编号	识别率/%	平均识别率/%
1	100	91.2
2	100	
3	77	
4	79	
5	100	

表4 实测雷达辐射源信号数据参数

辐射源	辐射源参数		
	调制类型	RF / MHz	PW / us
1	线性调频	9 813、9 618、9 623、9 648、9 753 五个频点波位组变, 频率分集	20
2	非线性调频	9 650 固定	16
3	非线性调频	9 817、9 853、9 742、9 768、9 775、9 832 六个频点波位组变	3~5 个脉冲一组, 每组PW 在 7、14 任意
4	常规脉冲	9 200~9 400 单脉冲捷变	3~5 个脉冲一组, 每组PW 在 1.1、1.2、1.3、1.4、1.5 任意
5	线性调频	9 413、9 418、9 424、9 448、9 454、9 466 六个频点波位组变	3~5 个脉冲一组, 每组PW 在 6、13、19 任意

由表4可见, 实测数据中雷达辐射源信号调制类型不同, 存在明显的交叠, 且载频RF、脉宽PW伴有捷变和抖动, 完全符合实际战场中复杂的电磁环境. 表4实验结果表明, 所提出方法对1、2、5号辐射源具有不错的识别效果, 3、4号辐射源由于参数存在显著跳变, 从而使得识别效果受限. 但是所提出方法对实测数据集的平均识别率仍然能够达到91.2%, 作为仿真实验的补充, 验证了在复杂多变的电磁环境下, 所提出方法具有一定的工程可行性.

#### 4 结 论

本文提出一种基于多域特征提取与集成融合学习对雷达辐射源信号进行识别的思路. 该方法在信息处理阶段能够较大程度上保留AF的内在细微特征, 同时避免了直接提取AF三维特征所需的较高复杂度和计算工程量; 然后, 在图像处理阶段采取了一种多域特征融合的两阶段识别方法, 可有效地提取和利用不同特征间的互补性, 并通过次级融合纠正初级阶段单个网络的错误识别结果, 提高识别精度, 得到最后的识别结果. 仿真实验结果和算法分析表明, 本文在不同信噪比下的平均识别率较高, 在低SNR条件下也有较好的表现, 具有一定的工程应用价值.

#### 参考文献(References)

[1] Konopko K, Grishin Y P, Jańczak D. Radar signal recognition based on time-frequency representations and multidimensional probability density function estimator[C]. Signal Processing Symposium. Debe, 2015: 1-6.

[2] Yi L, He Y G, Fang G F, et al. Application of modified Morlet wavelet in feature extraction of radar signal to intra-pulse[J]. Application Research of Computers, 2013, 30(1): 172-175.

[3] 余志斌, 金炜东, 陈春霞. 基于小波脊频级联特征的雷达辐射源信号识别[J]. 西南交通大学学报, 2010, 45(2): 290-295.  
(Yu Z B, Jin W D, Chen C X. Radar emitter signal recognition based on WRFCCF[J]. Journal of Southwest

Jiaotong University, 2010, 45(2): 290-295.)

[4] Świercz E. Automatic classification of LFM signals for radar emitter recognition using wavelet decomposition and LVQ classifier[J]. Acta Physica Polonica A, 2011, 119(4): 488-494.

[5] Chen C X, He M H, Xu J, et al. A new method for sorting unknown radar emitter signal[J]. Chinese Journal of Electronics, 2014, 23(3): 499-502.

[6] 韩俊, 陈晋汶, 孙茹. 复杂体制雷达辐射源信号识别新方法[J]. 雷达科学与技术, 2016, 14(1): 76-80.  
(Han J, Chen J W, Sun R. New method for recognizing complicated radar emitter signal[J]. Radar Science and Technology, 2016, 14(1): 76-80.)

[7] Xu Y C, Zhou Q S, Zhang J Y, et al. Radar emitter recognition based on ambiguity function features with derivative constraint on smoothing[J]. Acta Electronica Sinica, 2018, 46(7): 1663-1668.

[8] 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 Y W, Hou W T, Guo Y P, 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.)

[9] 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 W B, Zou Z Y, Xing W W. Feature fusion methods in pattern classification[J]. Journal of Beijing University of Posts and Telecommunications, 2017, 40(4): 1-8.)

[10] Xie Y X, Zhang L M, Zhong Z P. Radar signal identification based on time-frequency feature extraction and residual neural network[J]. System Engineering and Electronics, 2021, 43(4): 917-926.

[11] 普运伟, 刘涛涛, 郭江, 等. 基于卷积神经网络和模糊函数主脊坐标变换的雷达辐射源信号识别[J]. 兵工学报, 2021, 42(8): 1680-1689.  
(Pu Y W, Liu T T, Guo J, et al. Radar emitter signal recognition based on convolutional neural network and coordinate transformation of ambiguity function main ridge[J]. Acta Armamentarii, 2021, 42(8): 1680-1689.)

- [12] 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*, 2020, 20(21): 6350.
- [13] Wang W, Liu H, Yang J A, et al. Specific emitter identification using decomposed hierarchical feature extraction methods[C]. *The 13th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery*. Guilin, 2017: 1639-1643.
- [14] Zhang X N, Luo P C, Hu X W. A hybrid method for classification and identification of emitter signals[C]. *The 4th International Conference on Systems and Informatics*. Hangzhou, 2017: 1060-1065.
- [15] 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(11): 2420-2425.
- [16] Wei X, Yang Q X, Gong Y H. Joint contour filtering[J]. *International Journal of Computer Vision*, 2018, 126(11): 1245-1265.
- [17] Zheng Y P, Li G Y, Li Wei. Summary of the application of deep learning in image recognition[J]. *Computer Engineering and Applications*, 2019, 55(12): 20-36.
- [18] Huang Y K, Jin W D, Yan K, et al. Radar emitter signal identification via distance features[J]. *Journal of System Simulation*, 2021, 33 (12): 2959-2966.
- [19] Qu Z Y, Mao X J, Hou C B. Radar signal recognition based on singular value entropy and fractal dimension[J]. *Systems Engineering and Electronics*, 2018, 40(2): 303-307.
- [20] Pu Y W, Guo Y P, Hou W T, 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.
- [21] Yi J D, Yang J. Radar signal recognition based on IFOA-SA-BP neural network[J]. *System Engineering and Electronics*, 2020, 42 (12): 2735-2741.
- [22] Liu Y, Tian R L, Wang X F. Radar signal recognition method based on deep convolutional neural network and bispectrum feature[J]. *Systems Engineering and Electronics*, 2019, 41(9): 1998-2005.
- [23] 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.
- [24] Lu Z, Gong Y. Thoughts on the major challenge of radar emitter recognition technology and countermeasures[J]. *National Defense Science & Technology*, 2017, 38(2): 24-27.
- [25] 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.
- [26] 张立民, 谭凯文, 闫文君, 等. 基于多级跳线残差网络的雷达辐射源识别[J]. *系统工程与电子技术*, 2022, 44(7): 2148-2156.  
(Zhang L M, Tan K W, Yan W J, et al. Radar emitter recognition based on multi-level jumper residual network[J]. *Systems Engineering and Electronics*, 2022, 44(7): 2148-2156.)

### 作者简介

普运伟(1972—), 男, 教授, 博士生导师, 从事智能信息处理、模式识别等研究, E-mail: puyunwei@126.com;

余永鹏(1995—), 男, 硕士生, 从事智能信息处理的研究, E-mail: 1031767295@qq.com;

姜莹(1998—), 女, 硕士生, 从事教育智能化的研究, E-mail: 741188251@qq.com;

田春瑾(1982—), 女, 副教授, 博士生, 从事智能信息处理、教育智能化等研究, E-mail: jin\_05@163.com.