

基于多模态融合的小样本轻量化雷达有源干扰识别算法

张钟升¹, 李凉海², 张剑琦¹, 师亚辉¹

(1 北京遥测技术研究所 北京 100076;

2 中国航天电子技术研究院 北京 100094)

摘要: 随着雷达电子干扰技术的快速发展, 雷达所面临的有源干扰的多样性、干扰策略的变化性持续增长, 雷达对鉴别有源干扰类型的需求愈发迫切。传统的有源干扰特征识别方法识别效果有限且泛用性差, 现有的基于深度学习的方法参数规模较大且具有较高的数据需求, 限制了其自身的发展和应用。为在参数量和数据量有限的条件下提高有源干扰识别效果, 本文研究了基于多模态融合的小样本轻量化有源干扰识别算法, 利用时间局部性实现了信号时频特征及高分辨距离像特征的轻量化融合, 利用度量学习与特征检索技术提高了小样本情景下的干扰识别准确率。仿真和实测数据实验表明, 本文提出的方法在多种情况下具有良好的识别效果。

关键词: 有源干扰识别; 多模态融合; 轻量化神经网络; 小样本学习

中图分类号: TN974; TP183

文献标志码: A

文章编号: 2095-1000(2025)06-0122-14

DOI: 10.12347/j.ycyk.20250216001

CSTR: 32406.14.ycyk.20250216001

引用格式: 张钟升, 李凉海, 张剑琦, 等. 基于多模态融合的小样本轻量化雷达有源干扰识别算法[J]. 遥测遥控, 2025, 46(6): 122-135.

Lightweight Few-Shot Radar Active Jamming Identification Algorithm Based on Multi-Modality Fusion

ZHANG Zhongsheng¹, LI Lianghai², ZHANG Jianqi¹, SHI Yahui¹

(1. Beijing Research Institute of Telemetry, Beijing 100076, China;

2. China Academy of Aerospace Electronics Technology, Beijing 100094, China)

Abstract: With the swift advancement of radar jamming techniques, the variety of active jamming types and the diversity of jamming strategies have surged, urging for accurate identification of jamming types. Conventional active jamming identification methods lack efficiency and universality. Meanwhile, current deep learning-based approaches are encumbered by large-scale parameters and the need for extensive data, which significantly limit their practical applications. To enhance recognition capabilities under conditions with limited parameters and data, a lightweight few-shot radar active jamming identification method based on multi-modality fusion is proposed. Lightweight fusion is achieved by leveraging the temporal locality of time-frequency features and the high-resolution range profile features. Additionally, few-shot classification performance is improved through exploiting metric learning and feature retrieval techniques. Experiments conducted on both simulated and measured datasets demonstrate the superior performance of the proposed method under a variety of conditions.

Keywords: Active jamming identification; Multi-modality fusion; Lightweight neural network; Few-shot learning

Citation: ZHANG Zhongsheng, LI Lianghai, ZHANG Jianqi, et al. Lightweight Few-Shot Radar Active Jamming Identification Algorithm Based on Multi-Modality Fusion[J]. Journal of Telemetry, Tracking and Command, 2025, 46(6): 122-135.

0 引言

随着数字化技术、射频电子技术和智能化技术的快速发展, 现代数字射频存储认知干扰机产

生的有源干扰已能够实现对雷达信号的针对性压制和欺骗, 极大地威胁了雷达的目标探测能力^[1], 对雷达抗干扰系统提出了全新考验。目前的雷达抗干扰技术主要基于信号处理层面的干扰抑制和

电磁环境感知层面的干扰规避,二者均依赖于正确的干扰类型先验,因此有源干扰的类型识别研究对雷达抗干扰系统具有重要意义。

基于人工特征和机器学习的干扰识别方法已被广泛研究^[2]。文献[3]从时域、频域和时频域提取7种特征,使用决策树和支持向量机识别8种典型干扰,其识别率在94%以上。随着深度学习技术的繁荣发展和广泛应用,深度神经网络也已经被应用到雷达干扰识别工作中。例如,Meng等设计了一个复数卷积神经网络(Convolutional Neural Network, CNN)用于识别复合干扰样式^[4]。Lang等提出了一种结合了视觉Transformer(Vision Transformer, ViT)和CNN的轻量化干扰识别网络^[5]。Xiao等提出了一个基于时频域CNN的干扰识别框架,并评估了其开集识别能力^[6]。

深度学习在视觉和语言领域的巨大成功以及注意力机制的广泛使用进一步推动了多模态学习的研究。在干扰识别领域,由于契合了信号处理过程中模态和表示特性的多样性,多域或多模态融合方法被广泛研究。文献[7]提出了一种基于多卷积分支网络融合的干扰识别方法,通过融合原始信号与时频图的特征实现了多干扰的有效识别。文献[8]研究了扩展目标环境下多有源欺骗式干扰的识别问题,提出了一种基于注意力机制的、融合时频域和距离-多普勒域特征的识别方法,实现了对12种有源欺骗组合干扰的识别。文献[9]设计了一种融合时频分布特征和人工设计的时域和信息论特征的多模态融合网络,实现了8种压制和欺骗式有源干扰的识别。

为克服样本收集和标注带来的困难,小样本方法被引入雷达干扰识别领域。Luo等基于时频域自注意力机制和全局知识蒸馏方法设计了一个小样本干扰识别网络,并在一个仿真-实测混合数据集上验证了该网络的干扰识别性能^[10]。文献[11]提出了一种基于CNN孪生网络的干扰类型识别方法,可实现在小样本条件下干扰有效识别。文献[12]利用原型网络设计了一种多模态小样本有源欺骗干扰识别算法,并借助图像降噪处理和加权欧氏距离提高小样本和低信噪比下的识别性能。仿真结果表明,其方法在干噪比(Jamming to Noise Ratio, JNR)为3 dB时,10种雷达欺骗干扰的平均识别准确率达到97%。

针对实际应用场景中训练样本不足、模型参

数量大、计算复杂度高等问题,本文提出一种基于多模态融合的小样本轻量化雷达有源干扰识别算法,通过设计的轻量化交叉注意力机制实现了时频特征和高分辨一维距离像特征的特征融合,并利用余弦相似度损失和融合特征检索的决策方法提高了小样本识别效果。

本文的贡献如下:

①利用模态间的时间相关性设计了一种轻量化的多模态融合机制,在此基础上构建了一种用于有源干扰识别的轻量化多模态融合网络;

②利用原型学习和余弦相似度度量设计了一种组合损失,增强了小样本情况下的模型泛化能力,在此基础上实现了一种融合分类器预测结果和特征检索结果的决策融合方法,提高了识别精度;

③利用真实外场信号构建了一个雷达有源干扰数据集,在仿真和实测数据集上评估了本文方法,分析了模态、类别样本数以及噪声对模型识别效果造成的影响。

后文结构安排如下:第1章介绍信号的多模态表示方法;第2章介绍了轻量化的多模态融合干扰识别网络;第3章介绍面向小样本的余弦相似度组合损失设计和决策融合技术;第4、5章呈现了在仿真和实测数据集上的实验结果及结果分析;第6章总结了本文工作。

1 基于时频分析与匹配滤波的信号表示方法

1.1 短时傅里叶变换与时频表示

在干扰识别任务中,信号的时频表示因能够清晰直观地表征干扰信号的调制特性而被广泛采用。目前,相关研究中主要使用短时傅里叶变换(Short Time Fourier Transform, STFT)^[5,12]、小波变换^[13,14]、经验模态分解^[15]、崔-威廉斯分布^[9,13]等。

尽管STFT相比小波变换及其他二次型时频分布而言时频分辨率较差,但由于计算复杂度低、实现简单,STFT仍然是最广泛使用的时频分析手段。为尽可能降低资源消耗,本文采用STFT作为时频分析方法。

记待分析信号为 $s(t)$,窗函数为 $w(t)$,则STFT表示为

$$\text{STFT}(t, f) = \int s(\tau) w^*(\tau - t) e^{-j2\pi f\tau} d\tau \quad (1)$$

其中, t 为时间平移参数, f 为频率参数, $*$ 表示复共轭运算, j 为虚数单位。

1.2 脉冲压缩与高分辨距离像

记待分析信号为 $s(t)$, 参考信号(理论发射信号)为 $s_{ref}(t)$, 则匹配滤波器输出可表示为

$$MF(t) = s(t) * s_{ref}^*(-t) \quad (2)$$

其中, 二元运算符 $*$ 表示卷积。

当信号采样数较多时可采用频域匹配滤波, 计算方式为

$$MF(t) = \text{IFFT}(S(k) \times H(k)) = \text{IFFT}(\text{FFT}(s(t)) \times \text{FFT}(s_{ref}(t))) \quad (3)$$

其中, FFT、IFFT 分别表示快速傅里叶变换及其逆变换, $S(k)$ 、 $H(k)$ 分别为待分析信号和参考信号

的频谱。

匹配滤波后, 信号的距离分辨率得到提升, 因此匹配滤波后的信号形式也称为高分辨一维距离像(High Resolution Range Profile, HRRP)。HRRP 是发射波形对接收信号的匹配, 本文将 HRRP 作为时频分布以外的另一种输入模态, 用于特征融合与干扰识别。

2 轻量化多模态融合干扰识别网络

2.1 网络结构设计

图 1 展示了本文提出的多模态有源干扰识别模型。输入信号经预处理流程得到时频分布和 HRRP 两种模态数据, 通过提取和融合多域特征后得到识别结果。

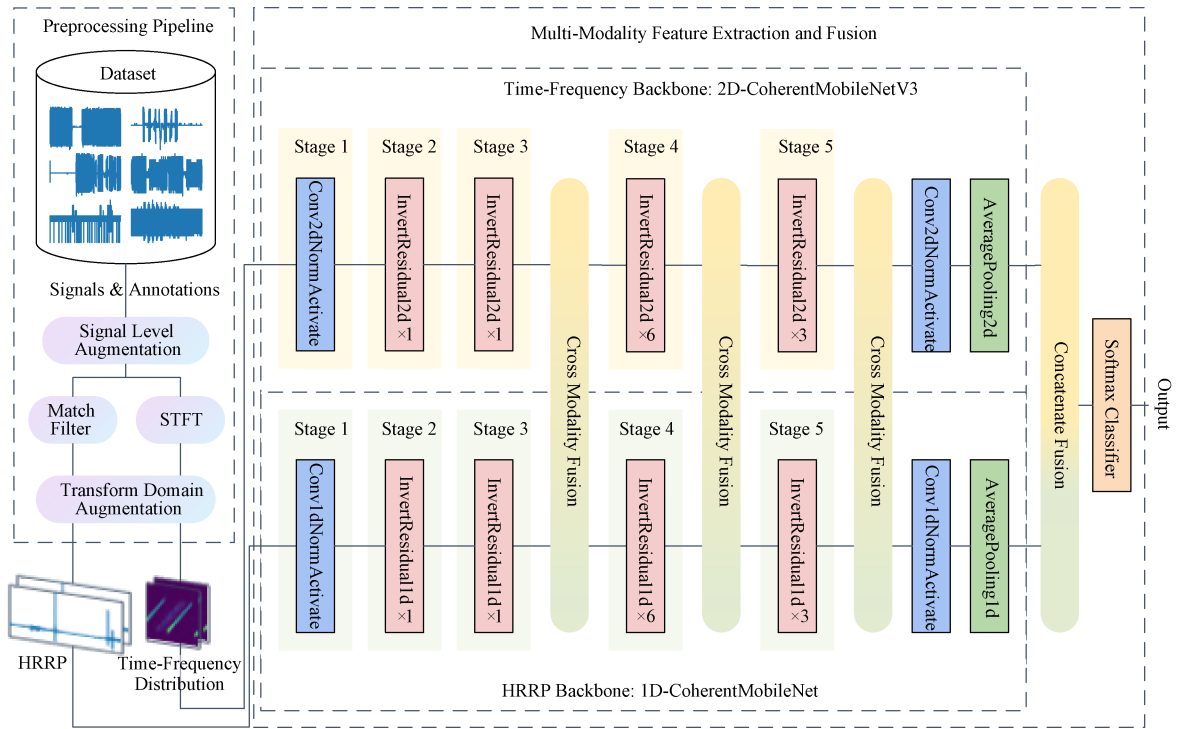


图 1 多模态有源干扰识别模型框图

Fig. 1 An overview of the proposed multi-modality active jamming identification model

信号预处理分为三级。第一级为信号级数据增强, 通过对信号做零均值处理、随机时移、白噪声混合以扩充样本分布; 第二级为域变换, 样本经匹配滤波和 STFT 后转换为两种不同模态; 第三级为变换域上的数据增强, 包括了样本的能量归一化、尺寸规范化和随机翻转。

本文设计的特征提取网络是两个互有交叉的分支, 按照输入模态分别称为时频域和脉压域主

干网络。两个主干网络均基于 MobileNetV3^[16] 设计。相比 MobileNetV3, 我们对两个主干网络做出如下适应性修改:

① 现有的研究通常将时频图而非时频分布本身作为 CNN 类特征提取网络的输入^[5, 9, 13]。时频图一般是由时频分布的幅度谱经颜色空间映射得到的三通道图像, 该输入形式只包含时频分布的幅度信息而损失了时频分布携带的相位信息。为利

用相位信息, 本文直接将时频分布作为时频域主干网络的输入, 修改输入层接收由时频分布实部和虚部组成的双通道数据。为便于区分, 称该网络为2D-CoherentMobileNetV3;

②为处理一维HRRP数据, 本文在保证网络宽度不变的情况下使用一维卷积代替MobileNetV3的二维卷积。为适应HRRP高分辨率的特点, 本文在脉压域主干网络中引入了膨胀卷积以增大感受野。脉压域主干同样以复信号作为输入。为便于区分, 称该网络为1D-CoherentMobileNetV3;

③为尽可能降低参数量和计算资源消耗, 本文将时频域主干宽度缩放至原来的0.4倍, 脉压域主干宽度缩放至原来的0.1倍;

④将相同分辨率的卷积层作为同一级, 时频域主干网络可分为五级, 对应了五次降采样卷积。本文在第三、四、五级后加入了特征融合层, 并在最后拼接两路特征向量, 得到最终的融合特征。

卷积模块(ConvNormActive)和反向残差瓶颈模块(InvertResidual)的实现与参数设置可参考文献[16], 2.2小节介绍了多模态特征融合模块。

2.2 基于时间相关性的轻量化多模态融合模块

多模态干扰识别框架的核心问题是各个模态之间的跨模态信息融合。目前, 基于交叉注意力的方法因其强大的跨模态自适应建模能力而受到广泛研究^[9, 12]。尽管基于交叉注意力的方法在融合性能上具备一定优势, 但因其计算复杂度随序列长度二次增长, 该方法在低计算资源场景中的应用受到限制。

考虑输入的两种模态均与时间存在严格对应关系, 其中, 时频分布中某一时间点 $\frac{i}{F_s}$ 的采样表示

示 $\left[\frac{i}{F_s}, \frac{i+N_{FFT}}{F_s}\right)$ 时间范围内信号的频率响应;

HRRP中某一时间点 $\frac{j}{F_s}$ 的采样表示 $\left[\frac{j}{F_s}, \frac{j}{F_s} + T_p\right)$ 时

间范围内信号的脉压响应。由于CNN特征提取的局部性, 在中间特征图中这种时间上的对应性质得到了保留。据此本文假设, 对于已经在时间上对齐的两个不同模态特征 $f_1(t)$ 和 $f_2(t)$, 只有在 $|i-j| < \tau$ 时 $f_1(i)$ 和 $f_2(j)$ 之间才是可关联的, τ 为一有限的可关联范围。

基于上述假设, 本文设计了一种针对时间对

齐多模态特征的交叉注意力计算方法, 删除不同模态时间跨度较大的特征之间的注意力连接, 仅对不同模态之间在一定时间范围内的特征计算注意力, 从而在降低计算消耗的同时避免了注意力的错误分配。

记 $f_1 \in \mathbb{R}^{C_1 \times F \times T_1}$ 为参与融合的时频域特征, $f_2 \in \mathbb{R}^{C_2 \times T_2}$ 为HRRP特征, 其中 C_1, F, T_1 分别表示二维时频特征图的通道数和大小; C_2, T_2 分别表示一维距离像特征图的通道数和长度。 $\tilde{f}_1 \in \mathbb{R}^{C_1 \times F \times T_1}$ 和 $\tilde{f}_2 \in \mathbb{R}^{C_2 \times T_2}$ 分别表示融合后的时频域和HRRP特征。

该模块的基本思想是将两个待融合特征按照时间段对应的原则切片, 不同模态同一时间片之间做交叉注意力后所有切片再重排回原特征大小。出于减少计算量的目的, 本文使用无重叠的时间片, 时间片数等于时频域特征时间维长度 T_1 。则对于时间片索引 s , 有

$$\begin{aligned} \hat{f}_1^{(s)}(i, j) &= f_1(j, i, s), \quad s=0, 1, \dots, T_1-1 \\ \hat{f}_2^{(s)}(i, j) &= f_2(j, sT_1+i), \quad s=0, 1, \dots, \frac{T_2}{T_1}-1 \end{aligned} \quad (4)$$

其中, 时频域特征序列 $f_1^{(s)} \in \mathbb{R}^{F \times C_1}$, HRRP特征序列 $f_2^{(s)} \in \mathbb{R}^{\frac{T_2}{T_1} \times C_2}$ 。为表示方便, 记两个张量为 $\hat{f}_1 \in \mathbb{R}^{T_1 \times F \times C_1}$ 和 $\hat{f}_2 \in \mathbb{R}^{T_1 \times \frac{T_2}{T_1} \times C_2}$ 。

式(4)对应了视觉Transformer中视觉特征图转换到特征序列的步骤, 即特征图分块(Patchify), F 和 T_2/T_1 可以视作交叉注意力的输入序列长度。与普通分块方法不同的是, 本文方法按照时间而非特征维度划分注意力头, T_1 即多头注意力运算中的注意力头数量。

本文设计的交叉注意力意在学习一个两模态共用的注意力矩阵, 根据该矩阵计算不同模态的注意力权重。为将查询张量与键张量值的特征维度对齐, 定义可学习权重 $\{W_i^K, b_i^K, W_i^V, b_i^V\}$, 时频和脉压分支的 K, V 张量表示为

$$\begin{aligned} f_i^K &= \hat{f}_i W_i^K + b_i^K \\ f_i^V &= \hat{f}_i W_i^V + b_i^V \end{aligned} \quad i \in \{1, 2\} \quad (5)$$

其中 $f_i^K \in \mathbb{R}^{T_1 \times F \times D}$ 为时频分支的键张量, $f_i^K \in \mathbb{R}^{T_1 \times \frac{T_2}{T_1} \times D}$ 为脉压分支的键张量。为减少冗余的跨模态信息交互^[17], 本文设置 $D = \min\{C_1, C_2\} = C_2$ 。 $f_1^V \in \mathbb{R}^{T_1 \times F \times C_1}$ 为时频分支的值张量, $f_2^V \in \mathbb{R}^{T_1 \times \frac{T_2}{T_1} \times C_2}$ 为脉压分支的值张量。

根据两模态的键张量计算共用的注意力矩阵:

$$A = \frac{f_1^K (f_2^K)^T}{\sqrt{D}} \quad (6)$$

其中 $A \in \mathbb{R}^{T_1 \times F \times \frac{T_2}{T_1}}$.

在对应的维度上计算最大值, 经 Softmax 归一化得到两模态的注意力权重:

$$\hat{W}_1 = \max_{0 \leq j < T_2/T_1} A_{h,i,j} \quad 0 \leq h < T_1, \quad 0 \leq i < F \quad (7)$$

$$(W_1)_h = \text{softmax} \left(\left(\hat{W}_1 \right)_h \right)$$

$$\hat{W}_2 = \max_{0 \leq i < F} A_{h,i,j} \quad 0 \leq h < T_1, \quad 0 \leq j < \frac{T_2}{T_1} \quad (8)$$

$$(W_2)_h = \text{softmax} \left(\left(\hat{W}_2 \right)_h \right)$$

使用注意力权重 W_1, W_2 对值张量加权:

$$f_1^a = W_1 \otimes f_1^V \quad (9)$$

$$f_2^a = W_2 \otimes f_2^V$$

将融合后分块序列 f_1^a, f_2^a 合并(Patch Merge)至原特征尺寸:

$$\dot{f}_1(i, j, s) = f_1^a(s, j, i), \quad s = 0, 1, \dots, T_1 - 1$$

$$\dot{f}_2(i, sT_1 + j) = f_2^a(s, j, i), \quad s = 0, 1, \dots, \frac{T_2}{T_1} - 1 \quad (10)$$

为稳定学习, 加入残差连接:

$$\tilde{f}_1 = \dot{f}_1 + f_1 \quad (11)$$

$$\tilde{f}_2 = \dot{f}_2 + f_2$$

图 2(a)展示了模块计算过程以及中间张量的形状和排布方式, 时间对应的切片(以相同线型表示)划分至同一注意力头; 图 2(b)给出了单头交叉注意力的计算示意图, 其中 \max_{-1} 、 \max_{-2} 是按行、列求最大值的简记, 二元运算符 \circ 表示函数的复合。

传统交叉注意力的主要性能瓶颈之一是 Softmax 注意力机制, 其时间复杂度为 $O(F \times T_1 \times T_2 \times D)$ 。表 1 给出了本文设计的多头交叉注意力模块的时间复杂度推导, 总计为 $O(F \times T_2 \times D) + O(F \times T_1 \times C_1)$, 较前者而言存在一定优势。此外, 通过在时间上限制注意力的关联范围, 本文提出的多

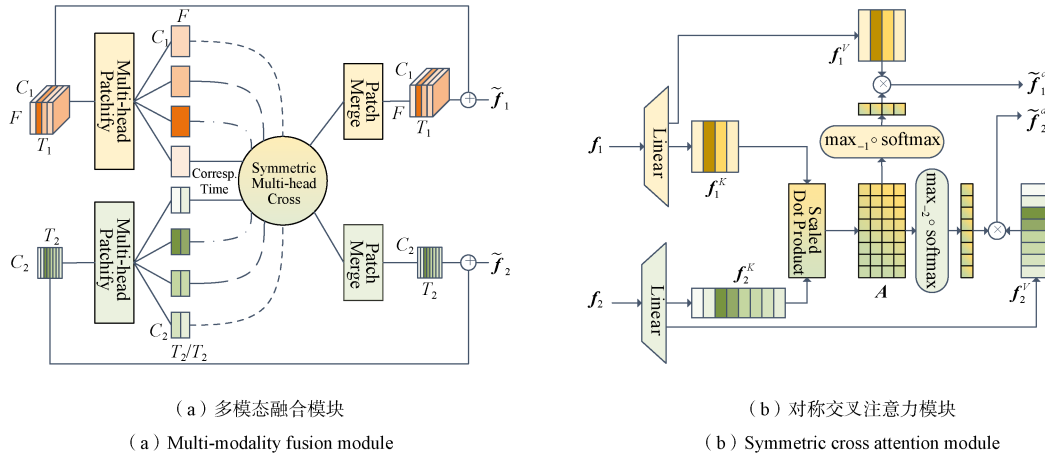


图 2 多模态融合模块与对称交叉注意力模块示意图

Fig. 2 An overview of the proposed cross modality fusion module and symmetric cross attention module

表 1 多头对称交叉注意力模块时间复杂度

Table 1 Time complexity of the proposed multi-head symmetric cross attention module

步骤	时间复杂度		
	时频分支	脉压分支	总计
计算共用的注意力矩阵		$O\left(T_1 \times F \times \frac{T_2}{T_1} \times D\right) = O(F \times T_2 \times D)$	
计算注意力权重	$O\left(T_1 \times F \times \frac{T_2}{T_1}\right) = O(F \times T_2)$	$O\left(T_1 \times F \times \frac{T_2}{T_1}\right) = O(F \times T_2)$	$O(F \times T_2)$
注意力加权	$O(T_1 \times F \times C_1)$	$O\left(T_1 \times \frac{T_2}{T_1} \times C_2\right) = O(T_2 \times C_2)$	$O(T_1 \times F \times C_1) + O(T_2 \times C_2)$
总计	/	/	$O(F \times T_2 \times D) + O(T_1 \times F \times C_1)$

模态特征融合方法缓解了不同距离上的时频和HRRP响应被错误关联的问题,进一步提升了模型的准确性。

3 小样本学习方法与融合检索的预测方法

3.1 原型学习与余弦相似度损失

受文献[18-20]启发,本文采用了一种基于原型学习和余弦相似度的损失函数。考虑一个类别数为 K 的多分类问题,记模型输出的最终特征为 $\mathbf{f} \in \mathbb{R}^D$,设有 K 个可学习的类别中心(原型, Prototype) $\mathbf{c}^k \in \mathbb{R}^D$,其中 D 为模型输出特征向量的维度, $k=0,1,\dots,K-1$ 。特征 \mathbf{f} 与第 k 类的类别中心 \mathbf{c}^k 的余弦相似度可表示为

$$s_k(\mathbf{f}) = \frac{\mathbf{f} \cdot \mathbf{c}^k}{\|\mathbf{f}\|_2 \cdot \|\mathbf{c}^k\|_2} \quad (12)$$

将 K 个余弦相似度组成的向量记为 $\mathbf{s}(\mathbf{f}) \in [-1, 1]^K$ 。该损失函数的思想是将相似度向量 $\mathbf{s}(\mathbf{f})$ 作为logits(原始未归一化分数),从而产生了一个基于余弦相似度的分类器(Cosine Similarity Classifier, CSC)^[19]。通过二元交叉熵(Binary Cross Entropy, BCE)等损失的梯度反传实现原型 \mathbf{c}^k 的学习,最终达到促进类内聚合的效果。

由于余弦相似度值域为 $[-1, 1]$,将相似度向量 $\mathbf{s}(\mathbf{f})$ 直接用作logits可能存在优化困难的问题,因此使用一个可学习的参数 τ 作为缩放因子。最终,对应第 k 类的logits表示为

$$l_{\text{csc}}^k = \tau \frac{\mathbf{f} \cdot \mathbf{c}^k}{\|\mathbf{f}\|_2 \cdot \|\mathbf{c}^k\|_2} \quad (13)$$

CSC输出的概率分布为

$$\mathbf{p}_{\text{csc}}^k = \text{softmax}(l_{\text{csc}}^k) = \frac{\exp(l_{\text{csc}}^k)}{\sum_{c=0}^{K-1} \exp(l_{\text{csc}}^c)} \quad (14)$$

若样本对应的类别标签为 $y^c = \begin{cases} 1, & \text{样本属于类别}c \\ 0, & \text{样本不属于类别}c \end{cases}$,则余弦相似度损失可表示为

$$\mathcal{L}_{\text{csc}} = \text{BCE}(\mathbf{p}_{\text{csc}}, \mathbf{y}) = - \sum_{c=0}^{K-1} y^c \log p_{\text{csc}}^c + (1 - y^c) \cdot \log(1 - p_{\text{csc}}^c) \quad (15)$$

此外,为了增大不同类别之间的隔离程度,本文借助学习到的聚类中心设计了类间隔离度

损失 \mathcal{L}_D :

$$\mathcal{L}_D = \max \left(\frac{1}{2} \sum_{0 \leq i < j < K} \frac{\mathbf{c}^i \cdot \mathbf{c}^j}{\|\mathbf{c}^i\|_2 \cdot \|\mathbf{c}^j\|_2}, m_p \right) \quad (16)$$

其中 m_p 为一个表示原型间隔的超参数。考虑到高维欧式空间中个数远小于维度数的一组向量容易做到两两正交, m_p 可设为0或一个极小值 $\varepsilon > 0$ 。

记Softmax分类器预测的概率分布为 \mathbf{p} ,则其交叉熵(Cross Entropy, CE)损失为

$$\mathcal{L}_{\text{ce}} = - \sum_{c=0}^{K-1} y^c \log p^c \quad (17)$$

综上,本文使用的损失函数为

$$\mathcal{L} = \mathcal{L}_{\text{ce}} + \lambda_{\text{csc}} \mathcal{L}_{\text{csc}} + \lambda_D \mathcal{L}_D \quad (18)$$

其中 $\lambda_{\text{csc}}, \lambda_D$ 为调节损失函数权重的超参数。

3.2 融合特征检索的预测方法

在预测阶段,Softmax分类头根据学习到的线性分类权重给出预测,余弦相似度分类头根据特征与类别原型的相似性给出预测。据此,本文设计了一种后期融合(Late Fusion)方式,根据置信程度融合两种不同预测。

定义概率分布最大值为置信度,按照两种预测的置信度加权求得融合概率分布 \mathbf{p}_{post} :

$$\mathbf{p}_{\text{post}} = \frac{\max(\mathbf{p})}{\max(\mathbf{p}) + \max(\mathbf{p}_{\text{csc}})} \cdot \mathbf{p} + \frac{\max(\mathbf{p}_{\text{csc}})}{\max(\mathbf{p}) + \max(\mathbf{p}_{\text{csc}})} \cdot \mathbf{p}_{\text{csc}} \quad (19)$$

4 仿真实验与结果分析

4.1 仿真数据生成

本文以脉冲线性调频信号为发射波形,按照表2所示参数生成了线性扫频(SWEEP)、梳状谱(COMB)、噪声乘积灵巧噪声(Noise Product, NP)、噪声卷积灵巧噪声(Noise Convolution, NC)、间歇采样直接转发(Interrupted Sampling Direct Jamming, ISDJ)、切片重构(Chopping and Interleaving, C&I)、频谱弥散(Smeared Spectrum, SMSP)、距离-速度拖引干扰(Range-Velocity Gate Pull-Off, RVGPO)共八种不同的干扰类型。每种干扰类型样本数为500。每种干扰类型的示例样本如图3和图4所示。

4.2 评价指标

本文采用多类别分类任务的评价指标评估干扰识别算法的性能,包括混淆矩阵、精确率(Preci-

表 2 数据集仿真参数

Table 2 Parameters of the simulated dataset

公共参数	值	干扰类型	参数	值
波形	脉冲正/负	线性扫频	调频率	32 ~256 GHz/s
	线性调频	梳状谱	频点个数	1~4
载频	3 GHz	噪声乘积 灵巧噪声	噪声标准差	0.01~10
带宽	2~4 MHz	噪声卷积 灵巧噪声	噪声标准差	0.01~10
			噪声脉宽	5~20 μ s
采样率	10 MHz	间歇采样 直接转发	采样次数	1~10
时宽	50~100 μ s	切片重构	切片数	2~10
采样点数	2 048	频谱弥散	调频率倍数	2~8
JNR	0~20 dB	距离- 速度拖引	拖引速度	0~200 m/s
			拖引加速度	0~50 m/s ²

sion)、召回率(Recall)、PR 曲线下面积(Area Under Precision Recall Curve, AUPRC)。

定义一对一的多分类混淆矩阵 $C \in \mathbb{N}^{K \times K}$, C_{ij} 表示标签类别为 i 的样本被预测为 j 的次数, K 为分类类别总数。定义 C_{kk} 表示第 k 类样本的真阳性(True Positive, TP), $\sum_{j=1, j \neq k}^K C_{kj}$ 为第 k 类样本的假阴性(False Negative, FN), $\sum_{i=1, i \neq k}^K C_{ik}$ 为第 k 类样本的假阳性(False Positive, FP), $\sum_{i=1, i \neq k}^K \sum_{j=1, j \neq k}^K C_{ij}$ 为第 k 类样本的真阴性(True Negative, TN)。

定义类别 k 的 Top-1 精确率(Top-1 Precision)为

$$P_k = \frac{C_{kk}}{\sum_{i=1}^K C_{ik}} \quad (20)$$

Top-1 召回率(Top-1 Recall)为

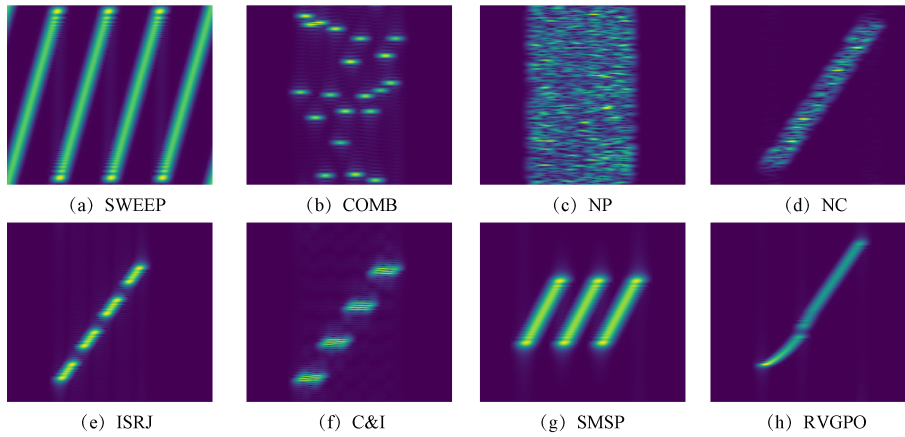


图 3 八种仿真干扰信号的时频分布

Fig. 3 Time-frequency distribution of eight types of simulated jamming signals

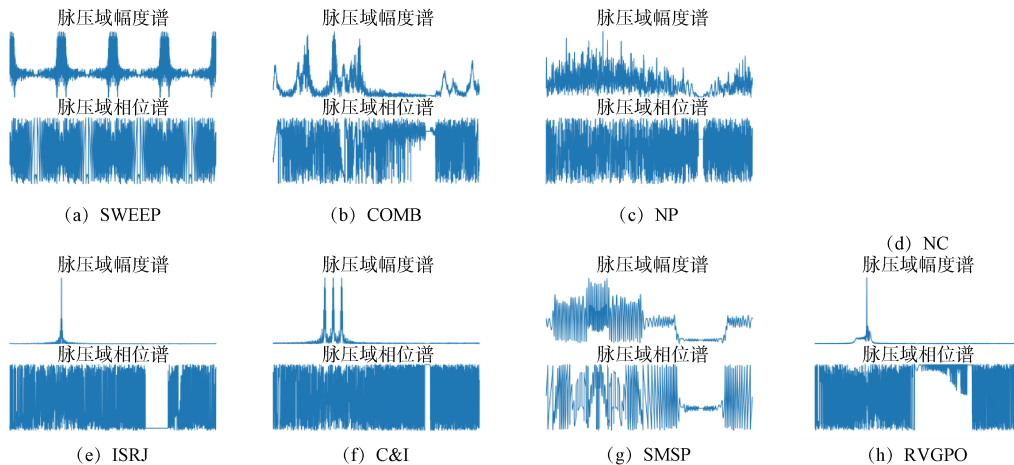


图 4 八种仿真干扰信号的高分辨一维距离像

Fig. 4 HRRP of eight types of simulated jamming signals

$$R_k = \frac{C_{kk}}{\sum_{j=1}^K C_{kj}} \quad (21)$$

为更好评价算法在实际场景中的效果,引入AUPRC作为评价指标。此时将多分类问题视为一对多分类,即对于任意一个类别而言,将其他类别作为另一种类别,进而转化成 K 个二分类问题。此时每个类别需要一个阈值用于二值化算法的输出概率(判断是否属于该类别)。每个类别的精确率和召回率与该阈值有关。一般而言,阈值越大,精确率越高,召回率越低。将不同阈值下的精确率-召回率绘制为一条曲线即为PR曲线,曲线下的面积即AUPRC:

$$AP_k = \sum_n (R_k^{(n)} - R_k^{(n-1)}) P_k^{(n)} \quad (22)$$

其中 $R_k^{(n)}, P_k^{(n)}$ 表示第 k 类样本对应第 n 个给定阈值的召回率和精确率。AUPRC最大为1,越接近1分类效果越好。

4.3 实验结果分析

本节从以下三个维度设计仿真实验:①无数据量约束情况下的多模态对比实验,主要验证方法的正确性以及基于不同模态的方法在当前数据分布上的分类性能;②小样本条件下的对比实验,主要研究样本数量对各方法的影响以及模型性能随样本数量的变化;③噪声鲁棒性实验,验证各方法的噪声鲁棒性。

本文参照文献[16]和文献[21]设置了训练超参数并应用一些常见的训练技术见表3。如未提及,后文默认使用这些策略和超参数。

4.3.1 多模态对比实验

实验1输入模态对分类的影响

以8:2划分训练集和测试集,不同模型分类指标如表4所示。为表示方便,记2D-CoherentMobileNetV3@width_mult=0.4为 f_{TF} ,记1D-CoherentMobileNetV3@width_mult=0.1为 f_{PC} ,

表3 训练策略与超参数

Table 3 Training strategies and hyperparameters

超参数		值
STFT	FFT点数	64
	窗	hamming, 33
	步长	$\lfloor N_{\text{samples}}/256 \rfloor$
resize	大小	256×256
	插值方法	双线性
优化器	方法	AdamW
	衰减	0.05
	学习率	$5E-4$
	训练轮次	200
	批大小	64
	梯度累加	2
学习率调度	方法	余弦退火(CosineAnnealingLR)
	warmup	linear, 10 epoch
	T_{max}	训练轮次

其中参数width_mult为网络的宽度因子; f_{fusion} 为本文在第2章中设计的多模态融合网络;“+CSC”表示结合本文第3章设计的基于余弦相似度的组合度量损失和后期融合策略。

由表4可以看出:

①对比实验1~3,在样本量充足的前提下,使用时频分布/时频图的主干网络均具有较强的干扰识别能力,在8类别仿真数据集上能够达到大于98%的识别率。基于HRRP的识别网络的识别率约为95%,但其在参数量和计算量上具有显著优势。

②对比实验4与实验1~3,相比于单一时频域/脉压域识别,本文提出的多域融合识别方法具有更高的识别率和平均精度,但这一差距在样本量充足的情况下并不显著。

③对比实验4与实验5,本文提出的基于余弦相似度的组合度量损失及相应的后期决策融合方法在样本量充足的情况下也能够有效提升识别精度。

f_{TF} 、 f_{PC} 及 f_{fusion} 的混淆矩阵如图5所示。

表4 不同模态或主干网络的分类指标

Table 4 Classification metrics of different modalities or backbones

序号	模态	模型	参数量	FLOPs	AUPRC	Precision	Recall
1	时频分布	f_{TF}	0.27 M	66.9 M	0.982 5	0.981 3	0.981 3
2	时频图像	JR-TFViT_S ^[5]	0.67 M	668 M	0.989 0	0.986 3	0.986 3
3	HRRP	f_{PC}	0.05 M	11.4 M	0.956 3	0.955 4	0.955 0
4	时频分布+HRRP	f_{fusion}	0.40 M	91.9 M	0.989 5	0.987 6	0.987 5
5	时频分布+HRRP	f_{fusion} +CSC	0.41 M	92.0 M	0.993 1	0.992 6	0.992 5

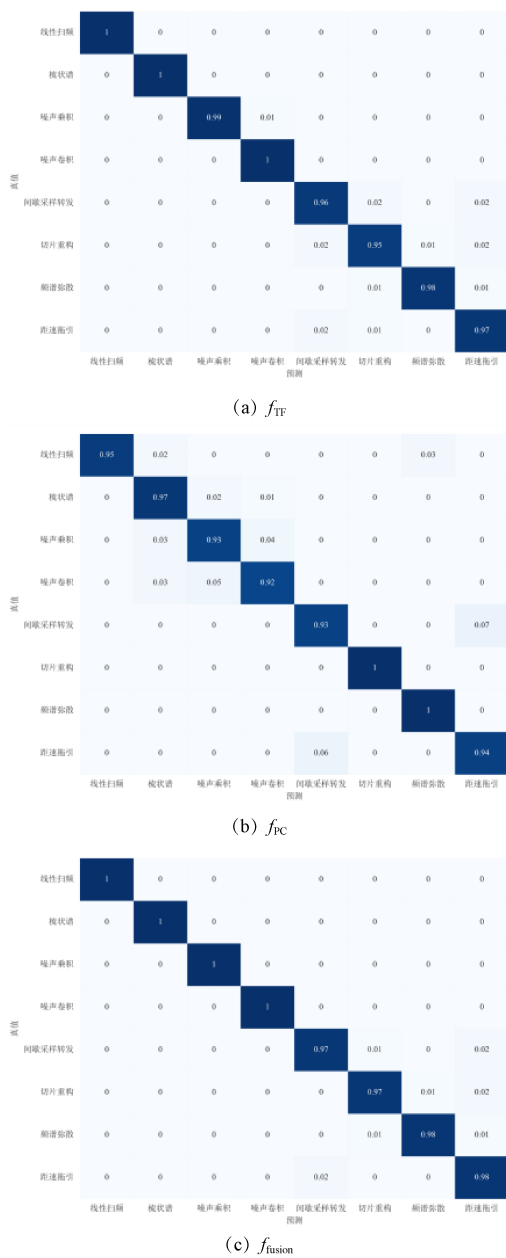


图 5 仿真实验中不同模态的混淆矩阵

Fig. 5 Confusion matrix of different modalities in simulation experiment under normal condition

对比图 5(a)和图 5(b)能够发现, 两种模态对不同样式干扰的识别能力存在差异。HRRP 网络对压制类干扰的识别能力相对有限, 但对欺骗式干扰的识别相对较好。时频类网络对波形和相对时延的敏感度较差, 但能够准确识别压制式干扰。与图 5(c)对比可见, 多模态融合网络在压制类干扰的能力基本与时频域模型相当, 而欺骗式干扰的识别效果略超过时频域识别模型, 这表明多模态融合网络能够结合不同变换域的优势, 实现多类别

的准确识别。

4.3.2 小样本条件下对比实验

实验 2 训练样本数对分类的影响

为测试小样本情况下前文所提出方法的效果, 本文将小样本干扰识别视为一个 8-way K -shot 问题, 并在 $K \in \{5, 10, 15, 20\}$ 的情况下分别训练模型并使用余下样本推导计算 AUPRC。为保证模型收敛, 我们在小样本实验中设置迭代次数 $iter_{max} = 30000$ 而不限制最大迭代轮数, 并且不再应用梯度累积策略。实验结果如表 5 所示。

表 5 仿真数据集上不同训练样本数下每种方法的指标

Table 5 Metrics of each method with different shots on simulated dataset

序号	模型	指标	K			
			5	10	15	20
1	f_{TF}	AUPRC	0.655 8	0.756 5	0.833 3	0.890 2
		Recall	0.676 3	0.775 0	0.833 8	0.893 8
		Precision	0.661 4	0.760 0	0.816 0	0.881 2
2	TF+CSC	AUPRC	0.674 8	0.790 2	0.866 4	0.929 0
		Recall	0.691 3	0.807 5	0.895 0	0.923 8
		Precision	0.687 6	0.808 3	0.898 5	0.929 1
3	JR-TFViT_S	AUPRC	0.696 3	0.789 5	0.857 5	0.902 7
		Recall	0.712 5	0.803 8	0.870 0	0.911 9
		Precision	0.709 0	0.799 5	0.868 9	0.904 7
4	f_{FC}	AUPRC	0.480 3	0.597 5	0.690 4	0.763 5
		Recall	0.506 3	0.621 3	0.705 0	0.767 5
		Precision	0.506 7	0.613 5	0.701 5	0.761 3
5	多模态融合网络	AUPRC	0.712 5	0.799 7	0.858 6	0.910 6
		Recall	0.748 8	0.808 8	0.856 3	0.920 0
		Precision	0.741 2	0.799 1	0.852 1	0.917 2
6	多模态融合网络+CSC	AUPRC	0.715 4	0.817 2	0.875 4	0.931 6
		Recall	0.746 3	0.830 0	0.881 3	0.938 3
		Precision	0.740 9	0.825 2	0.888 3	0.939 2

由表 4 可以看出:

① 对比 1、3、4、5 四组数据, 在所有被测的训练样本规模下, 多模态融合网络的识别效果都显著优于单一模态识别网络。 $K=5$ 时, 多模态相比单一模态的识别性能优势最大, 达到了 7.2%。 $K \geq 10$ 时, 随着训练样本数的提升, 单一时频域模型与多模态融合模型的识别性能差距减小。

② 对比实验 1 和实验 2、实验 5 和实验 6, 本

文提出的基于余弦相似度的度量学习损失与后期融合策略(CSC)能够较好地提高模型在小样本情景下的识别能力,这一提升在不同方法/模态/样本数的组合下均有效。

4.3.3 噪声鲁棒性实验

实验3 噪声强度对分类的影响

为验证模型对噪声的鲁棒性,本文在测试集干燥比{-10,-5,0,5,10}dB条件下计算AUPRC如图6所示。




图6 不同干燥比下各模型的性能指标
Fig. 6 Model metrics at different JNRs

从图6可以看出,干燥比大于0时,模型对干燥比的变化不敏感;干燥比小于0时干扰识别效果会受到一定影响,但基于时频域的模型均能够保持90%以上的识别准确率;干燥比降低20 dB,模型识别率降低均在10%以内。由于本文在训练中对信号加入随机强度的白噪声,因此各模型均具有较好的噪声鲁棒性。

5 实测数据验证与结果分析

5.1 数据简述

为进一步验证模型对真实信号与干扰样式的泛化能力,我们在外场采集了有源干扰数据并构建了实测数据集,场景布置如图7所示。试验期间共记录数据16段,每段按照单个脉冲干扰能量最

大的原则选取500帧作为样本。结合干扰机提供的干扰类型以及人工数据判读,形成了共包含8499条样本的有标注数据集,数据集样本类型分布如图8所示,其中杂乱脉冲干扰包含了两段数据,窄带瞄频、阵列假目标、灵巧噪声三个类别筛选了无效干扰,多音干扰不属于有意释放的干扰类型。图9展示了部分经过零均值化和图像增强的样本的时频分布。




图7 外场试验场景布置示意图
Fig. 7 An illustration of the outfield experiment




图8 数据集样本类型分布

Fig. 8 Category distribution of the measured dataset

5.2 实验结果分析

本节从以下三个维度设计实验:①无数据量约束的对比实验,在实测数据上验证多种模态不同方法的最优性能;②小样本条件下的对比试验,验证各方法在真实环境下的小样本分类性能;③特征可视化对比,可视化真实数据特征,验证方法的有效性和泛化能力。

5.2.1 多模态对比实验

实验4不同模态在实测数据集上的分类性能验证

按照8:2分割训练集和测试集,不同模型分类指标见表6。

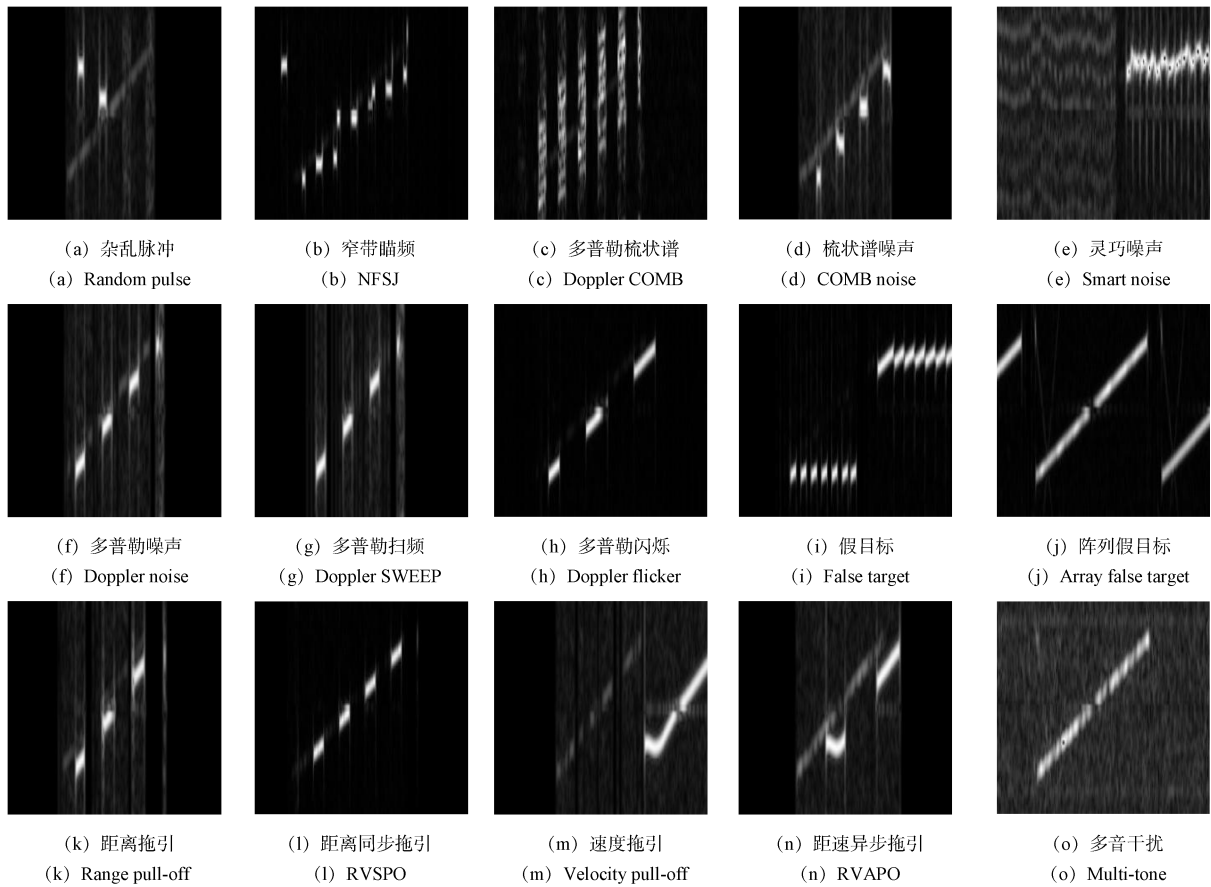


图 9 部分外场采集样本的时频分布

Fig. 9 Time-frequency distribution of some outfield collected samples

表 6 实测数据集上不同主干网络的分类指标

Table 6 Metrics on measured dataset by different backbone networks

模态	模型	AUPRC	Precision	Recall
时频分布	f_{TF}	0.980 9	0.955 4	0.954 6
时频图像	JR-TFViT _S ^[5]	0.981 8	0.960 2	0.954 8
HRRP	f_{PC}	0.925 2	0.905 3	0.885 9
时频分布+HRRP	f_{fusion}	0.982 8	0.962 5	0.954 1
时频分布+HRRP	f_{fusion} +CSC	0.984 7	0.957 2	0.955 2

时频域主干网络、脉压域主干网络和多模态融合网络的混淆矩阵如图 10 所示。

由图 10 可以看出:

① 样本量充足的情况下时频类主干网络在实测数据集上仍然能保持较高的干扰识别性能, 识别率均大于 95%。

② 相比于仿真数据集, 实测数据的混淆矩阵更具有趋同性。我们认为在真实场景中样本的多样性更强, 类别内样本与标准形式的差异也远超

仿真数据。当某两类干扰的表现形式、特征分布接近时, 容易发生个别样本难以区分的情况;

③ 注意到在上述的易混淆的类别上, 多模态融合方法相比两种单模态方法也存在一定提升, 我们认为多模态融合使得模型能够区分在任一模态上可分的样本, 一定程度上缓解了类别易混淆的问题。

5.2.2 小样本条件对比实验

实验 5 不同训练样本数在实测数据集上的分类性能验证

本小节的训练设置与 4.3.1 小节保持一致。对于实测数据集, 问题定义为 16-way K -shot 问题, 训练并测试 $K \in \{5, 10, 15, 20\}$ 的情况下各模型的性能, 结果见表 7。

从表 7 可以看出:

① 对比实验 1、实验 3、实验 4、实验 5, 在小样本情景下多模态融合方法相比单模态方法具有显著的识别性能优势, 在 $K=5$ 时识别性能提升最

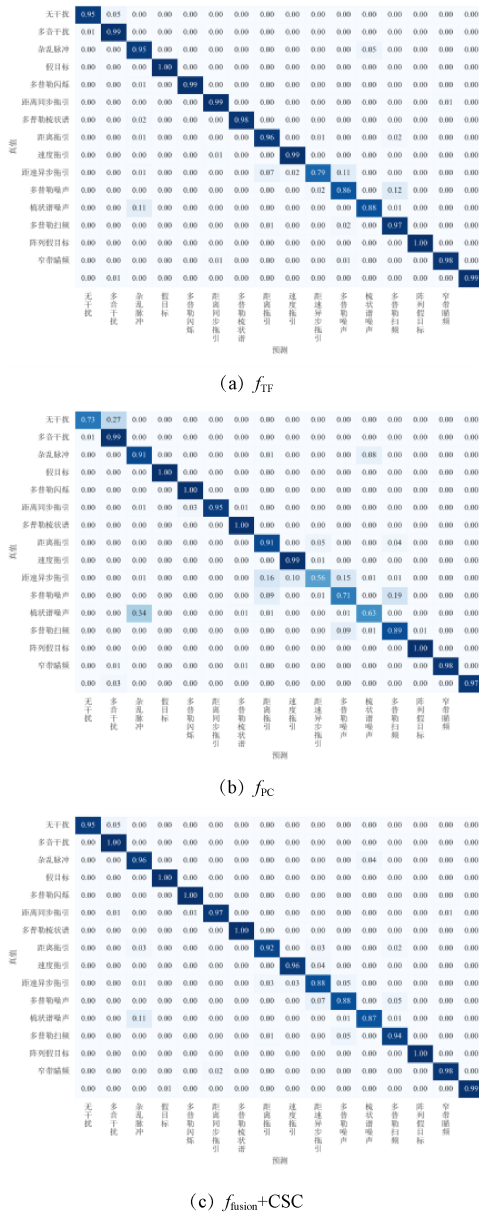


图 10 实测数据集上不同方法的混淆矩阵

Fig. 10 Confusion matrix of different methods on measured dataset

为明显，这一提升随着类别样本数的增大逐渐减弱，这也印证了实验 4 中训练数据充足时各模态识别效果相差不大的实验结果；

② 对比实验 1 和实验 2、实验 5 和实验 6，基于余弦相似度的组合度量损失及相应的后期决策融合方法在样本量较少的情况下可以提供较高的性能提升，这一效果在 $K \in \{10, 15\}$ 时更为显著，我们认为这是由于 CSC 需要类别样本体现整体规律，当类别样本数过低时，极少量的样本难以代表类别整体的特征分布，受样本选取的影响，其

表 7 实测数据集上不同训练样本数下每种方法的指标

Table 7 Metrics of each method with different shots on measured dataset

序号	模型	指标	K			
			5	10	15	20
1	f_{TF}	AUPRC	0.542 1	0.727 2	0.784 5	0.820 0
		Recall	0.567 8	0.724 3	0.773 3	0.821 8
		Precision	0.543 8	0.710 0	0.747 4	0.797 9
2	$f_{TF}+CSC$	AUPRC	0.564 8	0.775 6	0.816 8	0.860 5
		Recall	0.591 1	0.774 7	0.795 0	0.837 8
		Precision	0.572 1	0.778 0	0.778 5	0.808 9
3	JR-TFViT_S ^[5]	AUPRC	0.551 2	0.743 6	0.792 9	0.833 4
		Recall	0.583 0	0.744 1	0.780 5	0.829 6
		Precision	0.549 0	0.739 5	0.758 6	0.798 2
4	f_{PC}	AUPRC	0.379 9	0.628 0	0.652 5	0.669 6
		Recall	0.416 3	0.630 8	0.655 3	0.678 4
		Precision	0.406 7	0.613 5	0.631 5	0.652 3
5	f_{fusion}	AUPRC	0.639 8	0.732 9	0.794 3	0.816 6
		Recall	0.636 6	0.738 0	0.787 0	0.803 6
		Precision	0.618 3	0.719 1	0.762 1	0.770 6
6	$f_{fusion}+CSC$	AUPRC	0.687 3	0.787 4	0.818 2	0.845 0
		Recall	0.666 7	0.794 2	0.833 4	0.823 8
		Precision	0.662 7	0.787 1	0.792 9	0.815 2

提升效果不够稳定；当类别样本数相对充足时，模型本身的聚类能力增强，CSC 的性能提升效果相对下降。平均来看，CSC 对 f_{TF} 的召回率提升达到了 2.8%，对多模态融合方法的召回率提升达到了 3.8%。

5.2.3 特征可视化

为更形象地说明多模态特征融合以及余弦相似度损失的效果，本文在实测数据集上采集了实验 4 中模型的嵌入特征，使用 PCA(主成分分析)特征降维技术实现特征可视化。单时频域主干网络、多模态融合网络、使用余弦相似度损失的时频域主干网络的特征可视化结果如图 11 所示。

由图 11 可以看出：

- ① 单模态网络提取的特征具有一定的聚类性质，但有较多类别的类内聚集性较差，类间的可分性也较弱；
- ② 由于特征提取期间引入了其他模态，多模态融合网络提取的特征相比单模态网络具有更好的可分性和类内聚合性；
- ③ 基于余弦相似度的度量损失通过反向传播强调特征的聚类性质，其提取的特征的类内聚合



图 11 特征可视化对比

Fig. 11 Visualization comparison of embedded features.

度相比图 11(a)具有显著提高, 且特征之间的可分性更强, 这为小样本条件下的干扰识别提供了稳健的泛化能力。

6 结束语

本文针对雷达有源干扰识别任务所面临的样本数量少、计算资源有限等问题提出了一种小样本轻量化的多模态融合网络, 实现了时频域特征和高分辨一维距离像特征的自适应提取和融合; 提出了一种基于余弦相似度的组合式度量损失以约束类内聚合度和类间隔离度, 并利用余弦相似度损失学习的类别原型设计了一种融合特征检索的预测方法, 提高了小样本条件下模型的泛化能力和识别准确性。本文在仿真数据集和实测数据集上验证了提出的方法, 实验表明多模态特征融合网络较传统的单模态干扰识别模型而言有显著的识别性能提高, 提出的余弦相似度损失及预测方法能够改善特征分布, 提高小样本条件下的泛化能力。

参考文献

- [1] 崔国龙, 余显祥, 魏文强, 等. 认知智能雷达抗干扰技术综述与展望[J]. 雷达学报, 2022, 11(6): 974-1002.
CUI Guolong, YU Xianxiang, WEI Wenqiang, et al. An overview of anti-jamming methods and future works on cognitive intelligent radar[J]. Journal of Radars, 2022, 11(6): 974-1002. DOI:10.12000/JR22191.
- [2] 周红平, 王子伟, 郭忠义. 雷达有源干扰识别算法综述[J]. 数据采集与处理, 2022, 37(1): 1-20.
ZHOU Hongping, WANG Ziwei, GUO Zhongyi. Overview on recognition algorithms of radar active jamming [J]. Journal of Data Acquisition and Processing, 2022, 37(1): 1-20. DOI:10.16337/j.1004-9037.2022.01.001.
- [3] XU C, YU L, WEI Y, et al. Research on active jamming recognition in complex electromagnetic environment[C]// 2019 IEEE International Conference on Signal, Information and Data Processing (ICSIDP). [2024-08-14]. DOI: 10.1109/ICSIDP47821.2019.9173455.
- [4] MENG Y, YU L, WEI Y. Multi-label radar compound jamming signal recognition using complex-valued CNN with jamming class representation fusion[J]. Remote Sensing, 2023, 15(21): 5180. DOI:10.3390/rs15215180.
- [5] LANG B, GONG J. JR-TFViT: A lightweight efficient radar jamming recognition network based on global representation of the time-frequency domain[J]. Electronics, 2022, 11(17): 2794. DOI:10.3390/electronics11172794.
- [6] XIAO Y, ZHANG R, YU X, et al. Open-set recognition of compound jamming signal based on multi-task multi-label learning[J]. IET Radar, Sonar & Navigation (Wiley-Blackwell), 2024, 18(8): 1235-1246. DOI: 10.1049/rsn2.12561.
- [7] SHAO G, CHEN Y, WEI Y. Deep fusion for radar jamming signal classification based on CNN[J]. IEEE Access, 2020, 8: 102121-102131. DOI: 10.1109/ACCESS.2020.3004188.
- [8] KONG Y, WANG X, WU C, et al. Active deception jamming recognition in the presence of extended target[J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 1-5. DOI:10.1109/lgrs.2022.3184997.
- [9] 魏庚力, 李凉海, 闫海鹏, 等. 基于多模特征融合的雷达干扰信号识别[J]. 遥测遥控, 2023, 44(4): 80-87.
WEI Gengli, LI Lianghai, YAN Haipeng, et al. Radar jamming signal identification based on multimode feature fusion[J]. Journal of Telemetry, Tracking and Command,

- 2023, 44(4): 80-87. DOI:10.12347/j.ycyk.20230328001.
- [10] LUO Z, CAO Y, YEO T S, et al. Few-shot radar jamming recognition network via time-frequency self-attention and global knowledge distillation[J]. IEEE Transactions on Geoscience and Remote Sensing, 2023, 61: 1-12. DOI:10.1109/TGRS.2023.3280322.
- [11] SHAO G, CHEN Y, WEI Y. Convolutional neural network-based radar jamming signal classification with sufficient and limited samples[J]. IEEE Access, 2020, 8: 80588-80598. DOI:10.1109/ACCESS.2020.2990629.
- [12] 张顺生, 陈爽, 陈晓莹, 等. 面向小样本的多模态雷达有源欺骗干扰识别方法[J]. 雷达学报, 2023, 12(4): 882-891.
ZHANG Shunsheng, CHEN Shuang, CHEN Xiaoying, et al. Active deception jamming recognition method in multimodal radar based on small samples[J]. Journal of Radars, 2023, 12(4): 882-891. DOI:10.12000/JR23104.
- [13] 郭治锐, 鲁军, 刘磊, 等. 基于 AlexNet 的雷达干扰识别方法研究[J]. 电光与控制, 2021, 28(9): 49-53.
GUO Zhirui, LU Jun, LIU Lei, et al. Research on radar interference recognition method based on AlexNet[J]. Electronics Optics & Control, 2021, 28(9): 49-53.
- [14] 邵正途, 张路, 陈鹏, 等. 基于小波包分解和残差网络的雷达干扰识别[J]. 无线电工程, 2023, 53(4): 764-771.
SHAO Zhengtu, ZHANG Lu, CHEN Peng, et al. Radar jamming recognition based on wavelet-packet decomposition and residual network[J]. Radio Engineering, 2023, 53(4): 764-771.
- [15] 王慧娟. 雷达有源欺骗干扰识别技术研究[D]. 北京: 北京邮电大学, 2019.
- [16] HOWARD A, SANDLER M, CHEN B, et al. Searching for MobileNetV3[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV). IEEE, 2020. DOI:10.1109/ICCV.2019.00140.
- [17] NAGRANI A, YANG S, ARNAB A, et al. Attention bottlenecks for multimodal fusion[C]//Advances in Neural Information Processing Systems 34 (NeurIPS). Curran Associates, Inc., 2021: 14200-14213.
- [18] SNELL J, SWERSKY K, ZEMEL R S. Prototypical networks for few-shot learning[C]//Advances in Neural Information Processing Systems 30 (NeurIPS). Curran Associates, Inc., 2017.
- [19] GIDARIS S, KOMODAKIS N. Dynamic few-shot visual learning without forgetting[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2018: 4367-4375. DOI: 10.1109/CVPR.2018.00459.
- [20] LI Y, CHEN Y, YU X, et al. SURE: Survey recipes for building reliable and robust deep networks[C]//2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2024: 17500-17510. DOI: 10.1109/CVPR52733.2024.01657.
- [21] LIU Z, MAO H, WU C Y, et al. A ConvNet for the 2020s [C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2022: 11966-11976. DOI:10.1109/CVPR52688.2022.01167.

[作者简介]

- 张钟升 1999 年生, 硕士研究生。
李凉海 1965 年生, 硕士, 研究员。
张剑琦 1985 年生, 硕士, 研究员。
师亚辉 1977 年生, 硕士, 研究员。

(本文编辑: 杨秀丽)