

基于多任务学习和多域特征融合的雷达辐射源信号分选方法

普运伟^{1,2}, 赵辉杰¹, 李文康¹, 田春瑾¹

(1. 昆明理工大学信息工程与自动化学院, 昆明 650500; 2. 昆明理工大学图书馆, 昆明 650500)

摘要: 针对传统分选方法在复杂电磁环境下处理效率低下、分选准确率不足, 以及 5G 通信技术发展带来的雷达-通信频谱共享问题, 本文提出了一种基于多任务学习和多域特征融合的创新解决方法。该方法首先构建了一个多任务学习框架, 用于对含噪雷达-通信混合信号进行联合预处理, 包括信号清洗、降噪和时频特征增强。其次, 设计了特征融合网络, 分别从时频图像域与时延-多普勒域提取多尺度特征, 并采用改进的迭代注意力机制实现跨域特征融合, 生成具有强判别性的高维特征表示。最后, 基于 DeepCluster 的聚类模型完成对雷达辐射源信号的准确分选。实验结果表明, 在 -6 dB 低信噪比条件下, 该方法能够有效抑制通信信号干扰, 且达到 93.8% 的分选准确率。与现有方法相比, 所提方案在提升信号预处理的鲁棒性、保证分选准确率方面展现出显著优势, 具有良好的工程应用前景。

关键词: 雷达辐射源信号分选; 雷达通信频谱共享; 深度学习; 多任务学习; 注意力机制

中图分类号: TN974

文献标志码: A

引用格式: 普运伟, 赵辉杰, 李文康, 等. 基于多任务学习和多域特征融合的雷达辐射源信号分选方法[J]. 数据采集与处理, 2026, 41(4): 1058-1077. PU Yunwei, ZHAO Huijie, LI Wenkang, et al. A radar emitter signal sorting method based on multi-task learning and multi-domain feature fusion[J]. Journal of Data Acquisition and Processing, 2026, 41(4): 1058-1077.

引言

雷达辐射源信号分选(Radar emitter signal sorting, RESS)是指将侦察接收机截获的交织或重叠雷达信号分离为多个独立的雷达发射器类别, 为后续的辐射源识别、威胁评估及干扰决策等工作提供可靠依据^[1]。随着 5G 移动通信技术的快速发展和新型复杂体制雷达的广泛应用, 现代电磁环境呈现出信号密度高、调制样式复杂、时频重叠严重等新特点, 这对传统 RESS 方法提出了严峻挑战。现代雷达与通信系统在架构、工作频段和信号特征等方面具有较高相似性, 为实现频谱资源的高效利用并满足多样化的军用和民用场景, 雷达与通信频谱共享(Radar-communication spectrum sharing, RCSS)已成为当前亟需解决的关键问题^[2]。

传统 RESS 方法主要基于脉冲描述字等脉间特征进行信号识别, 然而在复杂电磁环境下其性能显著下降^[3]。时频分析(Time-frequency analysis, TFA)是一种用于研究非平稳信号的工具, 它能够同时在时间和频率维度上揭示信号的局部特征^[4]。现有研究在 TFA 基础上提出了多种改进方法, 例如 Hess-Nielsen 等^[5]和蒋闯^[6]分别使用优化变分模式分解方法二次提取信号特征和在 Choi-Williams 时频分布的基础上, 对图像进行伪 Zernike 矩和中心矩提取信号特征, 都获得了理想的特征表示。全大英

等^[7]提出基于多重同步压缩时频变换(Multi-synchro squeezing transform, MSST)及方向梯度直方图提取雷达辐射源信号特征的识别算法,在低信噪比下取得较高的识别准确度。侯文太等^[8]提出了一种基于高斯平滑与等高线的模糊函数(Ambiguity function, AF)特征提取新思路,将雷达辐射源信号分选问题转化为图像特征提取问题,实现对6类典型信号的有效分选。这些研究表明,稳健的特征设计和高效的分选算法是解决RESS问题的关键。

深度学习(Deep learning, DL)作为热门研究领域,在信号处理领域表现出强大潜力,尤其是神经网络在自动特征提取和分类识别方面展现了其优越性能。战权海等^[9]提出的基于改进Transformer的自动调制识别方法,通过由12层融合多头注意力机制的长短期记忆(Long short-term memory, LSTM)网络所构成的模块提取信号调制特征,显著提升了识别准确率;Altiparmak等^[10]使用多任务学习(Multi-task learning, MTL)和单任务神经网络分别学习雷达信号的测量参数并对其功能进行分类,实验结果验证了MTL技术的优越性。然而,现有基于DL的方法虽然能够自动提取高层语义特征,但这类直接从原始时域信号提取特征的方法难以准确反映信号的频率波动和能量分布,存在表征能力有限和可解释性不足等问题。

针对复杂电磁环境下雷达辐射源信号分选面临的新挑战,本文提出了一种基于多任务学习信号预处理(Multi-task learning signal preprocessing, MTLSP)与迭代注意力多域特征融合(Iterative attention multi-domain feature fusion, iAMFF)的RESS方法。该方法首先通过设置相关任务,充分挖掘任务间的潜在关联性,以并行方式协同完成雷达信号的降噪、清洗与时频特征增强,有效提升了信号预处理的鲁棒性。随后,为克服单一特征在识别高相似性信号时的表达局限,进一步从降噪后的雷达信号中提取模糊能量分布特征,并与其时频特征进行深度融合,生成具有更强判别性的高维特征表示。最终,用基于DeepCluster的半监督聚类策略,实现对雷达辐射源信号的有效分选。该方法在兼顾处理效率的同时,提升了复杂电磁环境下的分选准确率,经仿真与实测数据验证,展现出较好的性能,为复杂环境下的雷达信号智能分选提供了新的技术路径。

1 方法与模型

受人类可同时学习不同任务并实现知识迁移的启发,MTL通过联合学习相关任务实现知识共享,提升泛化能力,目前已在自然语言处理、计算机视觉和语音识别等领域应用并取得了优异的效果^[11-12]。

MTL通过共享模型参数提升多个相关任务的性能,如图1所示,主要分为硬参数共享和软参数共享^[13]。硬共享强制底层网络共用,仅顶层任务独立,计算高效但可能限制任务特异性;软共享允许任务参数独立但通过正则化约束相似性,灵活性更高但需平衡共享强度。图2为一般RESS方法流程图,其处理过程表现为串行方式。本文所提方法利用MTL架构的高效特性,将雷达信号预处理中的3个相关任务改进为协同并行处理方式,不同任务得以同步进行、参数共享。




图1 两种多任务学习方法

Fig.1 Two multi-task learning methods




图2 传统 RESS 方法流程图

Fig.2 Flowchart of traditional RESS method

1.1 MTLSP 模型

本文提出的多任务学习模型共设置 3 个相关任务,分别是信号清洗、信号降噪和信号特征增强。其中信号清洗任务和信号特征增强任务采用硬共享参数策略,而信号降噪任务与前两个任务采用软共享参数策略。混合参数共享策略通过动态结合硬共享的高效性和软共享的灵活性,对高相关任务共用底层网络,增强特征复用,对低相关任务参数独立,保留任务特异性,在计算效率和模型性能之间实现最优平衡,模型结构如图 3 所示。




图3 多任务学习模型示意图

Fig.3 Multi-task learning model illustration

1.1.1 信号特征增强

特征增强任务的核心目标,是从原始时域雷达信号里提取出来的特征质量更高、判别能力更强的信号,使后续的调制识别效果更好。对于信号 TFA,海森堡不确定性原理指出:信号在时域和频域的分辨率无法同时达到高精度,诸多 TFA 方法受限于此只能取得浓度有限的特征。同步压缩变换(Synchro squeezing transform, SST)成为研究提高 TFA 浓度的突破方向,其属于非参数 TFA 方法中的两步法,即先获得短时傅里叶变换(Short-time Fourier transform, STFT)结果,再进行压缩或提取操作以集中能量^[14]。

参考文献[14-16],可构建一个由 STFT 特征映射模块和基于残差编解码器(Residual encoder-decoder, RED)的能量集中模块构成的雷达信号特征增强网络。输入网络的原始雷达信号由特征映射模块转换到时频空间,得到多组带有丰富特征的粗略时频特征图像,随后,能量集中模块将这些特征图中时频(Time-frequency, TF)平面的能量压缩到真实的瞬时频率(Instantaneous-frequency, IF)轨迹上,最终得到时频图像(Time frequency image, TFI)。

(1) STFT 特征映射模块

为了获得更具判别性的雷达信号特征,使用包含一维卷积层的特征映射模块,通过卷积神经网络(Convolutional neural network, CNN)实现 STFT 矩阵权重的自适应学习,将原始时域雷达信号映射到时频域。CNN 具有强大的特征提取能力,将理想时频图像作为特征增强任务的监督目标,通过设置卷积核可以自适应地学习傅里叶基函数,该过程类似于 STFT 的“滑动窗口+傅里叶变换”。卷积核大小为 $1 \times L_s$, L_s 对应 STFT 的窗口长度,卷积核数量为 N ,使 $N = N_f \times C$,其中 N_f 对应 STFT 的频率分辨率, C 为卷积核划分的组数,卷积过程如图 4 上半部分所示。将特征映射中的卷积长度看作加窗,可以更好地反映信号时变特性,窗口大小 $L_w = L_s$ 。特征映射过程的卷积结果可以定义为




图4 特征映射模块示意图

Fig.4 Schematic diagram of feature mapping module

$$S_l(k) = \sum_{n=0}^{L_w-1} s_l(n) W_k(n) \quad k=0,1,\dots,N \quad (1)$$

式中: W_k 表示第 k 个卷积核, 步幅为 1, 填充为 $(L_s-1)/2$, 信号被截为 n 段, 每段信号表示为 $s_l(n)$, $l=1, 2, \dots, n; n=1, 2, \dots, L_w$ 。被窗函数截获的每个信号片段依次卷积, 获得 $L_s \times (N_f \times C)$ 的矩阵, 可等效为信号在当前时间窗口的 C 组 $L_w \times N_f$ 的粗略时频图像, 当整个信号卷积完获得 $(L \times N_f) \times C$ 的矩阵, 即 C 组特征图, 丰富了信号的时频特征。

(2) 基于 RED 的能量集中模块

经过特征映射模块, 获得了携带不同特征信息的多个特征图, 通过设计能量集中模块, 最终使 C 组 TF 特征图重建为时频图。参考文献[16]所提的 RED 网络, 能量集中模块主要由 20 个带有线性整流单元 (Rectified linear unit, ReLU) 的二维卷积层 (Conv_2D) 和 20 个对称的且同样带有 ReLU 的二维反卷积层 (DeConv_2D) 组成。卷积层起到特征提取的作用, 其能够在去除噪声的同时捕获图像中的重要特征。而反卷积层则能根据提取的特征恢复图像。需要注意的是, 深层的网络可能会导致特征丢失, 因此还需在每两个卷积层和相对的反卷积层之间添加跳跃连接, 这样可以使卷积层中提取的一些特征直接传递给反卷积层, 增加图像细节的保留。此外, 在模块的最后还需要添加一个转置卷积层 (ConvTranspose1d), 用于整合所有图像中的互补信息, 能量集中模块结构如图 5 所示。




图 5 能量集中模块示意图

Fig.5 Schematic diagram of energy concentration module

1.1.2 信号清洗

在实际雷达应用场景中, 截获信号不仅受到信道噪声的干扰, 还面临 RCSS 所引发的信号混叠问题, 即截获的雷达信号样本集中常会伴随有通信信号样本, 通信信号的干扰极易导致 RESS 工作的误判。因此, 在信号预处理阶段进行有效的信号清洗是保障 RESS 性能的关键环节之一。鉴于信号清洗任务与信号特征增强任务在目标和输入特性上存在高度相关性, 本文将二者作为相关任务, 通过硬参数共享的方式共同训练多任务学习模型, 以提升模型的协同泛化能力。信号清洗任务参数直接共享于信号特征增强任务路径, 由于获得的 STFT 特征图仍属于浅层特征表示, 尚不足以准确区分雷达信号与通信信号, 本文引入残差神经网络进行深度特征学习以增强模型对信号类别的判别能力。该任务本质为雷达信号与通信信号的二分类问题, 综合考虑模型性能与计算复杂度, 选择 ResNet18 来提取深度 TF 特征, 并通过 Softmax 分类器来完成识别^[17], 实现原理见图 3 中 Task 1。

1.1.3 信号降噪

针对截获信号中所包含的信道噪声,现有的RESS研究广泛采用了多种经典降噪技术,如均值滤波、维纳滤波、卡尔曼滤波以及小波变换等。这些方法在结构简单、计算代价低的同时,面对电磁环境复杂的实际场景,传统方法在降噪性能和自适应能力方面已难以满足需求。为提升信号降噪效果,相关研究人员提出大量基于深度学习的降噪方法,典型代表包括基于降噪自编码器、残差卷积神经网络、生成对抗网络以及 Transformer 等结构的降噪模型^[18-19]。这些方法通过深层特征建模与非线性表达能力,在处理强噪声和非平稳信号时表现出优越性能。受文献[20-22]中相关研究的启发,本文改进了一种 UNet 结构的信号降噪模型,以适应非平稳噪声特性与雷达信号特征的耦合关系,其具体结构如图 6 所示。Cin 和 Cout 分别表示卷积层的输入和输出通道数, K 为卷积核尺寸。




图6 雷达信号降噪模块示意图

Fig.6 Schematic diagram of radar signal noise reduction module

雷达信号降噪模块的输入为成对的有噪信号和纯净信号,网络通过学习掌握噪声数据和干净数据之间的映射,可以表示为 $\hat{y} = \mathcal{F}(x + n, \Gamma, \Theta)$, 其中 Γ 为噪声水平图, Θ 表示网络中的可训练参数, $\mathcal{F}$ 为映射关系。首先,需将长度为 N 的输入信号的实部和虚部分离,构成 $2N$ 维向量,使信号在时域上的特征可被 1 维卷积 (Conv1d) 和池化处理,便于提取信号时域局部特征。在信号输入到 UNet 之前,引入与输入数据同维度的噪声水平图 Γ , 作为正则化项平衡去噪过程中的“噪声抑制”和“信号保真度”,其元素由噪声方差 σ 拉伸构成, σ 越大,模型对噪声的敏感度越高,反之更注重保留原始信号特征。输入有噪信号形状为 $[b_{sz}, 2N]$, 经噪声水平估计子网络将噪声估计特征与原始信号特征结合,补充 Γ 并连接为 $[b_{sz}, 4N]$ 的数据,作为 UNet 降噪网络的输入, b_{sz} 为每次训练迭代的批次大小。

UNet 是一个对称的网络结构,其下采样路径可进行特征提取,上采样 (Upsampling) 路径则完成信息重建,该设计可利用多尺度信息并逐步扩大感受野。在 UNet 降噪网络中,先是通过 1 维卷积 (Conv1d) 和平均池化 (Mean-pooling) 逐步提取高层特征,输出通道数依次 64、128、256,扩大感受野以捕获长距离时域依赖关系。再利用转置卷积和填充恢复信号维度,结合下采样路径的跳跃连接,将高层语义特征与底层细节特征融合,确保去噪后信号的结构完整性。

考虑到信号降噪任务相较于信号特征增强任务和信号清洗任务相关性稍弱,为了保持降噪任务的特异性,避免负迁移,所以在 MTLSP 模型,信号降噪任务通过软参数共享的方案与前两个任务实现参数交互,见图 3 中 Task 2。

1.1.4 不确定性损失权重平衡

为了使上述不同的相关任务在训练过程中参数共享、节省计算资源并联合优化,需要为各任务合理设计损失函数,并构建一个有效的联合损失函数。

信号特征增强任务的重点是对 TFI 进行重构,采用均方误差(Mean squared error, MSE)损失函数可以衡量重构图像与目标图像之间像素级的差异,再引入感知损失函数(Perceptual loss),用于从更高层次(如图像纹理与结构)评估重构图像在感知上的相似性,从而提升图像的主观质量。MSE 公式表示为

$$\mathcal{L}_{\text{MSE}}(y, y') = \frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2 \quad (2)$$

式中: n 为图像中像素点的总数, y_i 为目标图像中的第 i 个像素, y'_i 为生成图像中的第 i 个像素。感知损失的基本思想是比较生成的图像和目标图像之间的高级特征的差异,这些特征是由预训练的 VGG16 网络提取的。对于 VGG16 网络的第 j 层,损失函数为

$$\text{Loss}_{\text{feat}}^{c,j}(y, y') = \frac{1}{C_j W_j H_j} \left\| \varphi_j(y) - \varphi_j(y') \right\|_2^2 \quad (3)$$

式中: φ 表示 VGG16 网络, j 为层索引, $\varphi_j(y)$ 和 $\varphi_j(y')$ 分别为目标图像和生成图像通过 VGG16 网络第 j 层的特征, C_j 、 W_j 和 H_j 分别为第 j 层特征的通道数、宽度和高度。将每一层的损失函数相加,得到整个感知损失,可以表示为

$$\mathcal{L}_{\text{feat}} = \sum_{j=0}^N \text{Loss}_{\text{feat}}^{c,j}(y, y') \quad (4)$$

式中 N 为 VGG16 网络的总层数。对于特征增强任务,使用复合目标函数可表示为

$$L_s = \alpha \mathcal{L}_{\text{MSE}} + \beta \mathcal{L}_{\text{feat}} \quad (5)$$

信号清洗任务目标是判断干扰类型或识别信号是否被污染,其本质上是一个监督分类任务。因此,采用交叉熵(Cross entropy, CE)损失函数,用于度量模型输出的类别概率分布与真实标签之间的差异。交叉熵损失公式为

$$\mathcal{L}_c = \frac{1}{n} \sum_{i=1}^n \mathcal{L}_i = -\frac{1}{n} \sum_{i=1}^n \sum_{c=1}^M y_{ic} \ln(p_{ic}) \quad (6)$$

式中: M 为信号类别的总数, y_{ic} 为符号函数(如果第 i 个信号的真类别等于 c ,则取1,否则取0), p_{ic} 为第 i 个信息属于第 c 个类别的预测概率。

对于信号降噪任务,同信号特征增强任务一样属于重构问题,同样采用 MSE 作为该任务的损失函数,用于衡量降噪后信号与真实纯净信号之间的点对点差异。MSE 损失能够有效反映信号重构的精度,有助于模型在训练过程中稳定收敛并获得更高质量的降噪结果。信号降噪任务的 MSE 损失函数公式为

$$\mathcal{L}_r(x, \hat{x}) = \frac{1}{2N} \sum_{i=1}^2 \sum_{j=1}^N \left[\mathcal{F}(\hat{x})_{i,j} - x_{i,j} \right]^2 \quad (7)$$

式中: $\hat{x} = x + n$ 表示输入的有噪信号, x 为纯净信号作为监督目标。

在多任务学习中,各任务的损失量纲不同、收敛速度不一致,若人为设定固定的损失权重,容易导致某些任务主导优化过程,进而影响整体性能。为了自适应地平衡各任务之间的优化权重,本文引入不确定性损失权重平衡(Uncertainty-based loss weighting)机制。该方法基于贝叶斯概率模型的思想,通过引入每个任务的不确定性参数,在训练过程中动态调整各任务损失的权重,从而实现了对多任务学习过程的自动调节与权衡,提高模型整体性能与收敛稳定性^[23]。可定义 MTL 的总损失为

$$\mathcal{L}_{\text{total}} = \sum_i \left(\frac{1}{2\sigma_i^2} \mathcal{L}_i + \ln \sigma_i \right) \quad (8)$$

式中: $\mathcal{L}_i$ 为第 i 个任务的原始损失(如 MSE、CE 等); σ_i^2 为第 i 个任务的预测不确定性方差(为可训练参数), 通过 $1/2\sigma_i^2$ 可以控制每个任务损失的权重, 不确定性越低, 损失权重越高, 表明模型对该任务更“自信”, 反之, 不确定性越高, 损失权重越低, 表明模型对该任务更“保守”; $\ln \sigma_i$ 为正则项, 用于防止 σ_i 无限限制缩小。对于本文所提多任务学习模型, 其总损失函数可表示为

$$\mathcal{L}_{\text{total}} = \frac{1}{2} \sum_{i=1}^3 (e^{-s_i} \mathcal{L}_i + s_i) = \frac{1}{2} (e^{-s_1} \mathcal{L}_1 + e^{-s_2} \mathcal{L}_2 + e^{-s_3} \mathcal{L}_3 + s_1 + s_2 + s_3) \quad (9)$$

式中 $s_i = \ln \sigma_i^2$ 。该联合损失函数可使模型能自动聚焦于当前阶段相对容易学习、收敛更快的任务, 减少任务冲突。

1.2 信号特征选取与高效融合模型

雷达辐射源信号在经过 MTLSP 模型处理后会产生两个有效输出: (1) 经特征增强得到的 TFI; (2) 降噪雷达信号。其中, TFI 是一种典型的时频域特征表示, 能够有效反映信号频率随时间变化的动态特征, 对于多数调制类型具有良好的可分性和可视化效果。然而, 在低信噪比条件下, 或是面对某些时频分布较为模糊、交叠严重的调制方式时, 如图 7 所示的 Frank 信号和 P1 信号, 相似的图像往往难以全面表征信号的深层特征和结构规律。为此, 还需要寻找更多的信号特征作为补充, 通过特征融合模型进行有效的特征融合, 形成最终聚类分选的判据。

1.2.1 基于模糊函数的特征提取

模糊函数通过描述信号在时延-多普勒平面上的能量分布, 揭示了信号在时延域与频移域的相关特性, 能体现其内在的结构模式。不同的调制方式, 其 AF 图像表现出明显不同的能量分布形态, 例如某些线性调频信号会在模糊域呈现沿多普勒方向拉伸的主脊线, 而跳频或相位调制信号可能在多个区域出现离散能量块^[24]。

对于雷达辐射源信号 $s(t)$, 可以表示为

$$s(t) = g(t) e^{j(2\pi f_0 t + \varphi_0)} = [a(t) e^{j\theta(t)}] e^{j(2\pi f_0 t + \varphi_0)} \quad (10)$$

式中: f_0 和 φ_0 分别为信号的载频和初始相位, 取决于信号的调制类型; $g(t)$ 为信号复包络, 其中的 $a(t)$ 表示幅度调制函数, $\theta(t)$ 表示相位调制函数。信号 $s(t)$ 的模糊函数 $\chi_s(\tau, \xi)$ 由其复包络 $g(t)$ 所决定, 定义为

$$\chi_s(\tau, \xi) = \int_{-\infty}^{+\infty} g\left(t + \frac{\tau}{2}\right) g^*\left(t - \frac{\tau}{2}\right) e^{-j2\pi\xi t} dt \quad (11)$$

式中: τ 为时延, ξ 为多普勒频移, t 为时间, $g^*(t)$ 为 $g(t)$ 的共轭复数。式(11)表明, AF 本质上为 $s(t)$ 匹配滤波器对给定时延-多普勒信号的响应, 能够较好地反映信号内在结构特性。

在 AF 图像中, 能量在中心原点处取得最大值, 且具有双轴对称性, 见图 8(a~c), 主脊切面(即通过最大能量轴向切片)反映了信号最强相关的传播路径, 常用于提取信号的主导结构特征; 而侧切面(与主脊正交的方向)则揭示了信号的局部扰动与调制细节^[25]。AF 频移零点切片特征和时延零点切片特征可分别由式(12、13)表示




图7 Frank和P1信号在不同SNR下TFA图像

Fig.7 TFA images of Frank and P1 signals at different SNRs

$$|\chi(\tau_1, \xi)| = \begin{cases} |g(t)e^{j2\pi\xi\tau_1} \otimes g^*(-t + \tau_1)| & \tau_1 \neq 0 \\ \left| \int_{-\infty}^{+\infty} g(t)^2 e^{j2\pi\xi t} dt \right| & \tau_1 = 0 \end{cases} \quad (12)$$

式中 $\tau = \tau_1 \neq 0$ 时的 AF 切片可等效为输入信号为 $g(t)e^{j2\pi\xi\tau_1 t}$ 的频移回波信号通过一个匹配滤波器, 并沿频移轴将 τ_1 时刻的输出值展开; 相似地, 式(13) $\xi = \xi_1 \neq 0$ 时的 AF 切片可等效为输入信号 $g(t)e^{j2\pi\xi_1\tau t}$ 的时延回波信号通过一个匹配滤波器并在 ξ_1 时刻沿时延轴展开的输出值。

$$|\chi(\tau, \xi_1)| = \begin{cases} |g(t) \otimes g^*(-t + \tau) e^{-j2\pi\xi_1\tau}| & \xi_1 \neq 0 \\ \left| \int_{-\infty}^{+\infty} g(t) g^*(t + \tau) dt \right| & \xi_1 = 0 \end{cases} \quad (13)$$

获取 AF 时延零点切片和频移零点切片后, 根据 AF 的对称性原理将两种切片的半轴进行组合可得到 AF 正交切片 (Ambiguity function orthogonal slice, AFOS), 如图 8(d) 所示。选取模糊函数的正交切面作为特征输入, 不仅可以避免使用完整二维 AF 图像所带来的冗余维度问题, 还能通过低维切片捕捉到关键的结构性差异。AFOS 兼具紧凑性与判别性, 尤其在 TFI 特征表现不佳的情况下, 可以与 TFI 特征在多域特征融合框架下进行联合学习, 为信号识别与分类提供有效的辅助判据, 提升模型对复杂信号的判别能力与鲁棒性。




图8 LFM 信号模糊函数及其切面

Fig.8 LFM signal ambiguity function and its cross-sectional display

1.2.2 iAMFF 模型

从融合策略出发, 特征融合方法大致可分为 4 类: 特征级融合 (Feature-level fusion)、决策级融合 (Decision-level fusion)、混合融合 (Hybrid fusion) 以及模型中融合 (Intermediate-layer fusion), 其中模型中融合是一种在模型的中间层通过显式或隐式机制实现不同域特征交互的融合方式, 强调特征在深层语义空间中的耦合与补充。针对雷达辐射源信号这一类形式多样、结构复杂且易受噪声干扰的非平稳信号,

单一域的特征表达往往难以全面捕捉其调制规律和分布特性。本文选取雷达辐射源信号的时域-频域TFI与时延-多普勒域AFOS作为多域特征来源,构建了一种以模型中融合为核心的混合融合策略——iAMFF模型,以实现深层次的特征互补。TFI包含了雷达信号频率随时间变化的动态轨迹,能够清晰展现信号调制方式和瞬时频率特征,选用EfficientNet作为特征提取主干网络,在保持网络结构轻量化的同时,具备较强的多尺度建模能力和参数效率,能够有效提取TFI中局部纹理与全局趋势等关键信息。AFOS源自模糊函数在时延-多普勒域的正交切面投影,其能量分布结构具有较强的判别性和稳定性,能够刻画不同调制信号在结构层面上的差异,利用MLP处理AFOS曲线,可以有效捕捉其在幅度模式、变化速率等方面的统计特征和形态信息。

首先对不同域获得的特征向量进行维度对齐与归一化处理,随后通过迭代注意力特征融合(Iterative attentional feature fusion, iAFF)模块^[26]实现深层融合,实现方法如图9所示。iAFF模块通过多个多尺度通道注意力模块(Multi-scale channel attention module, MS-CAM)交替迭代更新融合权重,突出各特征分量中对当前任务最有贡献的部分,进而有效保留不同模态中的关键信息,并抑制冗余与噪声干扰。




图9 迭代注意力多域特征融合模型示意图

Fig.9 Schematic diagram of iterative attention multi-domain feature fusion model

1.3 改进的聚类算法

为了进一步挖掘雷达信号中的潜在结构信息,本研究使用DeepCluster方法对融合特征进行半监督聚类,采用“聚类——伪标签——再训练”的迭代机制,具体流程如算法1所示。首先,将由iAMFF模型所提取的融合特征与真实标签一起,进行短周期的有监督训练,引导模型特征空间初步分化,获得初始特征提取能力,也能提高训练的稳定性。然后,将这些融合特征使用K-means聚类算法将样本划分为若干簇,并将聚类结果作为“伪标签”赋予样本,即构建为新的伪标签训练集。紧接着,使用伪标签训练集继续训练模型,优化其表示能力。这个过程不断迭代,通过特征学习与聚类目标的相互促进,实现更具判别性的特征空间构建。在DeepCluster半监督训练之后,再使用真实标签对模型进行监督微调,从而进一步提升模型的性能。该策略兼顾了无监督特征建模的泛化能力与有监督微调的准确性要求,在复杂背景下实现了更稳健的雷达信号识别能力。

算法1 改进的DeepCluster聚类算法

输入:

训练数据集 $\{(x_i, y_i)\}_{i=1}^N$ (包括融合特征和类别标签)

类别数 class

输出:

DeepCluster模型

Step 1: 有监督预训练

For epoch 1

使用真实标签 (x_i, y_i) 对模型进行短周期有监督训练

End for

Step 2: 半监督训练

For epoch 2

对所有训练样本 $\{x_i\}$ 的融合特征进行K-means聚类

聚类结果作为伪标签 $\{\hat{y}_i\}$,构建新训练集 $\{(x_i, \hat{y}_i)\}$

使用伪标签 $(x_i, \hat{y}_i)$ 对模型进行半监督训练

迭代优化模型参数

End for

Step 3:有监督微调

For epoch 3

使用真实标签 (x_i, y_i) 再训练

End for

保存最佳模型

1.4 模型整体流程与数据传递

本文所提基于MTLSP和iAMFF的RESS方法整体流程如图10所示,系统在接收到有噪混合信号后,经多任务学习模型,在清洗掉通信信号的同时,也输出增强的TFI和降噪后的雷达信号。计算降噪雷达信号的AFOS后,将TFI和AFOS进行深度特征融合,输出高维特征向量。最后由聚类模块对特征向量进行分选,得到由不同雷达信号组成的聚类簇。




图10 本文方法整体流程

Fig.10 Overall process of the proposed method

2 实验设计与结果分析

2.1 构建雷达数据流

为验证本模型的可行性和有效性,本文实验中所用数据采用仿真生成的常规脉冲信号(Conventional pulse, CON)、线性调频信号(Linear frequency modulation, LFM)、四频移键控信号(4-frequency shift keying, 4FSK)、二进制相移键控信号(Binary phase shift keying, BPSK)、Frank码相位编码信号(Frank code phase-coded signal, FRANK)、Costas跳频编码信号(Costas frequency hopping coded signal, COSTAS)、P1、T1共8种雷达辐射源信号和频移键控信号(Frequency shift keying, FSK)、脉冲幅度调制信号(Pulse amplitude modulation, PAM)、相移键控信号(Phase shift keying, PSK)、正交幅度调制信号(Quadrature amplitude modulation, QAM)共4种通信信号,所有信号均添加高斯白噪声,SNR分布为 $[-10, 10]$ dB,采样频率为200 MHz,每种信号生成各200个,总数据为26 400个。各类雷达信号参数如表1所示。通信信号载波频率为25 MHz,编码内容为随机生成32位二进制数。数据按照7:2:1划分训练集、验证集和测试集,即18 480个训练样本,2 640个测试样本。

表 1 雷达信号数据参数设置
Table 1 Radar signal data parameter settings

调制	参数名称	符号	参数大小
CON	载波频率	f_c/MHz	30
LFM	载波频率	f_c/MHz	25~50
	带宽	B/MHz	12.5~25
FSK4	载波频率	f_c/MHz	25~50
BPSK	载波频率	f_c/MHz	25~50
	巴克码	N_c	{7, 11, 13}
FRANK	载波频率	f_c/MHz	25~50
	主干频率	M	4~8
COSTAS	载波频率	f_c/MHz	30
	Costas 码	code	1, 2, 4, 8, 5, 10, 9, 7, 3, 6
P1	载波频率	f_c/MHz	25~50
	主干频率	M	4~8
T1	载波频率	f_c/MHz	25~50
	段数	k	4~5

实验在配备 Intel Core i5-13600KF CPU、32 GB DDR4 内存、NVIDIA GeForce RTX 4060 GPU 的台式机上进行,操作系统为 Windows 11。测试环境包括 MATLAB 2023A、Python 3.12 和 PyTorch 2.5.1(CUDA 12.6 支持)。

2.2 MTLSP 模型配置与实验效果

MTLSP 由 3 个任务模块组成,不同任务在训练的过程中通过不确定性损失权重平衡机制自适应任务间的协调,通过不断地迭代找到最优的任务配比。其中特征增强任务网络的结构如表 2 所示。

表 2 网络结构参数
Table 2 Network structure parameters

网络	层数	层参数
特征增强模块	Complex-Valued Conv1d	$C_{in}=1, C_{out}=2\ 048, K=(1, 31)$
	Conv2d#1+ReLU	$C_{in}=16, C_{out}=32, K=(3, 3)$
	Conv2d#2—#20+ReLU	$C_{in}=32, C_{out}=32, K=(3, 3)$
	Conv2d#1—#19+ReLU	$C_{in}=32, C_{out}=32, K=(3, 3)$
	Conv2d#20+ReLU	$C_{in}=32, C_{out}=16, K=(3, 3)$
	ConvTranspose1d	$C_{in}=16, C_{out}=1, K=(3, 1)$

在训练过程中,引入不确定性损失权重的目的是实现多任务损失之间的动态平衡,通过为每个任务引入可学习的权重参数,根据各任务的不确定性自动调整其在总损失中的贡献。图 11 展示了在该机制下各损失函数及其权重随训练过程的演化情况。可以看到,总验证损失整体呈稳定下降趋势,表明模型整体性能不断提升。损失函数 1 和 3 在初期快速下降并趋于稳定,其对应的权重也较早减小并保持在较低水平,有效控制了对总损失的贡献;而损失函数 2 下降过程较为缓慢,但在训练后期逐渐趋于稳定,对应的权重则始终相对较高,保证了其在总损失中的占比,促进模型对该任务的持续学习。整体来看,不确定性加权机制能够根据任务难度动态调整优化方向,提高了多任务学习的稳定性和效果。

经过MTLSP模型较长时间的优化,特征增强模块能够有效学习雷达信号的时频结构,并实现高质量的时频图像重构。图12展示了在不同SNR条件下,模型对LFM信号进行时频特征提取与增强的可视化结果。图12(a)为MSST的时频图像,图12(b)为模型输出的增强TFI,可以观察到,相较于前者,模型生成的图像在保持信号主要特征的同时,增强了细节表现力,轮廓更加清晰,结构更加连续。尤其在低SNR条件下,增强TFI依然能够较好地保留信号的关键特征,体现出较强的鲁棒性和良好的特征学习能力,有助于提升RESS的可靠性和准确率。

在信号清洗模块中,依托特征增强模块所提取的有效判别特征,以及ResNet在分类任务中的优越性能,该模块在实验中表现出较好效果。即使在SNR为 -10 dB的低SNR条件下,仍能够实现100%的通信信号清洗准确率。进一步实验表明,直至SNR降至 -14 dB,信号清洗效果才开始表现出不稳定性,验证了该方法在强噪声环境下依然具备良好的鲁棒性与适用性。

信号降噪模块能够对输入信号中的噪声强度进行自适应建模与预测,基于U-Net的信号重建网络通过多层次的特征提取与逐步恢复机制,能够充分保留信号结构信息并逐步剥离噪声干扰。降噪模块还结合了多任务学习框架中共享的特征参数,作为判别噪声与有效成分的参考,进一步提升模型对多种信号类型的兼容性和泛化能力。图13展示了信号降噪模块在0 dB时的降噪效果,可见模型能有效提升信号质量,验证了所提方法的有效性。

2.3 iAMFF模型实验效果

对于 N 个待分选信号,传入该模型的数据分为两部分:(1)经MTLSP的Task 3输出的TFI数据,其形状为 $[N, 256, 256]$;(2)由MTLSP的Task 2输出的降噪雷达信号,计算得到每个信号的AFOS,形状为 $[N, 512]$ 。为使不同的特征能够顺利被iAFF模块接收并融合,选择使用轻量且高效的EfficientNet-B0网络提取TFI的有效特征,输出形状为 $[N, 128]$ 的向量,再用MLP提取AFOS获得形状同样为 $[N, 128]$ 的特征向量,iAFF模块能通过多尺度卷积注意力机制,充分提取、融合雷达信号的时频特征以及模糊函数特征,输出128位长度能有效表征不同调制方式的雷达信号之间差异的特征向量。图14展示了LFM、FRANK和P1信号在SNR为0 dB时各自时频图像特征、模糊函数正交切面和融合后特征的分布直方图。从图14可以看出,LFM信号特征主要在 $[-20, 20]$,分布较为分散,两侧有长尾,FRANK和P1主要在 $[-10, 15]$,二者峰值位置相近,主峰均在横坐标坐标原点左侧,分离特征不明显,与前文所述相同,FRANK和P1两类信号在TFA图像上所表现的特征具有一定的相似性。在加入AFOS后,经融合的特征向量表现出更大的差异,其中LFM特征仍较为分散且有明显长尾,FRANK相




图11 不确定性损失权重平衡迭代过程

Fig.11 Balancing iterative processes by uncertainty loss weights




图12 模型特征增强模块效果

Fig.12 Effect of feature enhancement module




图 13 0 dB时模型信号降噪模块效果展示

Fig.13 Effect of signal denoising module at 0 dB




图 14 特征融合模型效果展示

Fig.14 Effect display of feature fusion model

较于P1特征分布更加集中,并且在峰值形态和尾部频率均表现出差异,表明该方法具有有效性。

2.4 信号特征选取与消融实验

为进一步验证特征选取的合理性及所提出特征融合模块的有效性,本文设计了多组对比与消融实验,分别对不同特征组合及融合策略在聚类任务中的表现进行评估。实验分别选取模糊函数主脊切面

(Ambiguity function main ridge, AFMR)和WVD分布(Wigner-Ville distribution)作为对比特征,并引入替代融合模块AFF和不进行融合、直接拼接特征向量的方式作为对照组进行消融分析。所有实验均在SNR为−6 dB~0 dB条件下进行,每类雷达辐射源仿真信号选取200个样本,共计6 400个样本,信号参数设置详见表1,实验结果如表3所示。

表3 消融实验结果

Table 3 Ablation experiment results

实验方法	SNR/dB			
	0	−2	−4	−6
本文方法	0.998	0.971	0.837	0.565
AFF+TFI+AFOS	0.996	0.962	0.741	0.460
TFI+AFOS(拼接)	0.997	0.956	0.725	0.438
iAFF+TFI+AFMR	0.995	0.971	0.807	0.544
iAFF+TFI+WVD	1.000	0.971	0.745	0.416

实验结果显示,本文采用的TFI与AFOS特征在表达雷达辐射源信号结构信息方面具有较强的互补性,融合后的特征在分选任务中取得了优异性能。尤其在中低SNR条件下,所提方法展现出更强的鲁棒性和稳定性。第2,3组为消融实验,不难看出本文方法所用的特征融合模块起到了重要作用,在不同SNR下总体表现优秀。分析第4,5组的特征对比实验,虽然WVD在高SNR条件下凭借其优越的时间-频率分辨率良好,但其对噪声敏感,在低SNR条件下性能明显下降;AMFR取得了与AFOS最相近的实验结果,因为AFMR图像对称,其中一半为冗余信息,而AFOS含有AFMR中的全部信息并且还额外包含模糊能量分布的侧切面,所含特征显著高于AFMR,所以能取得更高的分选准确率。

2.5 整体实验效果及对比

为了验证整体方案的有效性,在训练集上完成100轮迭代训练后,实验对测试集中的2 640个混合信号进行分选,其中雷达信号1 760个,通信信号880个。信号在MTLSP模块处理阶段,信号清洗任务能够有效筛选掉全部的通信信号,保证后续雷达信号的分选工作能够顺利开展。剩下的1 760个不同SNR信号在经过特征融合后分选,整体准确率达到89.0%。为体现该方法在不同应用场景下的表现效果,进一步分离不同SNR的测试样本并扩充数据集,模拟不同SNR环境下进行实验,实验结果如表4所示,在SNR>0 dB时,模型能准确地分选各类信号,随着SNR降低,准确率呈逐渐下降趋势,但在−8 dB时仍能取得接近85%的准确率,该方法体现出较强的分选能力和较好的鲁棒性。

表4 不同SNR分选结果

Table 4 Sorting results of different SNRs

SNR	10 dB	8 dB	6 dB	4 dB	2 dB	0 dB
Acc	1	1	1	1	1	0.999
SNR	−2 dB	−4 dB	−6 dB	−8 dB	−10 dB	Mixed
Acc	0.987	0.977	0.938	0.848	0.745	0.890

图15展示SNR分别为−6 dB和0 dB时实验信号聚类的混淆矩阵,观察图像可知对于结构较为简单的CON信号和LFM信号,模型总能准确地把握其特征,而P1和T1信号,则较容易受噪声干扰,在低SNR时会被以不同概率分到其他种类信号中。并且在图15中还能看出经过AFOS对TFI的特征补充,原本特征具有相似性的FRANK信号和P1信号没有出现明显的混淆情况。




图 15 模型分选混淆矩阵

Fig.15 Model sorting confusion matrix

为进一步验证所提方法在复杂噪声条件下的实际分选能力,本文选取文献[15-18]中的典型方法作为对比基线,补充开展对比实验,相关结果如图 16 所示。可以观察到,本文提出的模型在不同 SNR 条件下均表现出良好的稳定性,随着 SNR 逐渐降低,模型分选性能并未出现“断崖式”下跌,显示出较强的抗噪声鲁棒性。CSRDNN^[18]识别精度相对较低,是因为该方法由 LSTM、门控循环单元 (Gated recurrent unit, GRU) 和双向门控循环单元 (Bidirectional gated recurrent unit, BGRU) 3 个循环神经网络构成,主要关注时域特征,难以捕获频域信息,导致其特征融合能力受限。而本文所提方法将时域信号映射到时频域,可以捕获时间依赖性和详细的频域信息,为识别提供更多判别特征。

MTL based method^[15]在高 SNR 时表现良好,而随着 SNR 降低其准确率迅速下降,是因为该方法采用端到端的 MTL 模型进行分选,却未对待分选信号进行有效的预处理,使得模型在面对强噪声背景时难以提取稳健的时频特征表示,抗干扰能力相对较弱。AFOS+CNN^[17]融合了信号在多个计算域上的特征,并基于 CNN 结构进行分选。同样在高 SNR 条件下,该方法得益于良好的特征提取能力而分选准确率较高。但由于其采用基于决策级的特征融合策略,难以获得信号深层特征,当 SNR 逐渐降低,ResNet18 对弱特征的建模能力不足,此方法的分选准确率也大幅降低。低截获概率 (Low probability of intercept, LPI)-Net 方法^[19]在低 SNR 条件下表现优越,具备较强的抗干扰能力。然而,该模型对噪声不敏感的特性在高 SNR 条件下反而会削弱其对信号细节特征的捕捉能力,造成关键信息的丢失,进而影响分选效果。相比上述方法,本文提出的方法在降噪能力、特征表达力与分选性能之间取得良好平衡,因而在各类 SNR 条件下均展现出优秀的稳定性与抗干扰能力。

2.6 实测雷达数据实验

为验证本文提出方法的应用价值,采用某雷达场外实测数据进行实验分析,选取 8 种雷达辐射源产




图 16 不同模型实验效果对比

Fig.16 Comparative analysis of experimental results across various models

生的各 500 个信号,总计 4 000 个样本。经过实验,本文方法的平均准确率为 0.869,具体识别结果如表 5 所示。作为对比,文献[15]所提方法依赖深度学习策略进行信号分选,学习的过程中由神经网络自主学习信号特征,有较好的泛化性,因而对于不同辐射源信号的分选不存在明显的偏差,但该方法对于不同类别信号的个体特征较难把握,使其整体识别准确率略低。文献[17]所提方法通过提取 3 种信号特征进行融合分选,由于限定的特征泛化性不足以及决策级特征融合难以获得信号深层特征,该方法仅在部分辐射源信号上取得理想分选准确率。本文方法除信号 1、3 出现混淆以及信号 2 识别率较低外,其余 5 类信号都在 99% 以上正确率。究其原因,是因为两种常规脉冲参数过于相近,本模型主要用于识别不同调制方式下的雷达辐射源信号,对相同调制方式以频率为主要差异的信号识别能力不足,后续研究工作将着手改善这一问题。

表 5 实测雷达数据分选准确率
Table 5 Sorting accuracy of measured radar data

模型方法	辐射源 1	辐射源 2	辐射源 3	辐射源 4	辐射源 5	辐射源 6	辐射源 7	辐射源 8	平均
本文方法	0.60	0.72	0.65	0.99	1.00	0.99	1.00	1.00	0.864
文献[15]方法	0.76	0.77	0.75	0.83	0.91	0.89	0.87	0.91	0.836
文献[17]方法	0.85	0.60	0.32	0.81	0.99	0.93	0.99	0.97	0.808

表 6 所示为实测雷达辐射源信号的数据参数,可以看出辐射源信号的调制类型包括线性调频、常规脉冲和非线性调频,且频率和脉宽表现出捷变、波位组变和频率分级等复杂特性,各参数间均有不同程度的交叠,基本符合实际战场复杂多变的电磁环境,说明本文所提方法具有一定的应用价值。

表 6 实测雷达辐射源信号数据参数
Table 6 Measured radar emitter signal data parameters

信号	调制类型	射频频率(Radio frequency, RF)/MHz	脉冲宽度(Pulse width, PW)/ μ s
1	非线性调频	9 782、9 882	3~5 个脉冲一组,每组 PW 在 0.8、0.9、1.0、1.1、1.2 任意
		2 个频点波位组变,频率分集	
2	常规脉冲	9 840、9 880、9 920	3~5 个脉冲一组,每组 PW 在 0.8、0.9、1.0、1.1、1.2 任意
		3 个频点波位组变	
3	线性调频	9 720、9 630、9 690	3~5 个脉冲一组,每组 PW 在 0.7、0.8、0.9、1.0、1.1 任意
		3 个频点波位组变,频率分集	
4	常规脉冲	9 788 固定	3~5 个脉冲一组,每组 PW 在 0.4、0.5、0.6 任意
5	非线性调频	9 793、9 762、9 832、9 822、9 778、9 808 这 6 个频点波位组变	3~5 个脉冲一组,每组 PW 在 7、13 任意
6	非线性调频	9 522、9 548、9 517、9 562、9 553、9 512 这 6 个频点波位组变	3~5 个脉冲一组,每组 PW 在 6、12、18 任意
7	线性调频	9 682 固定	8
8	非线性调频	9 617、9 653、9 624、9 648、9 612 这 5 个频点波位组变	3~5 个脉冲一组,每组 PW 在 25、32、50 任意

3 结束语

为应对复杂多变电磁环境中雷达通信频谱共享条件下雷达辐射源信号的有效分选问题,本文提出了一种基于多任务学习信号预处理与迭代注意力多域特征融合的雷达辐射源信号分选方法。该方法

通过MTLSP模块在截获的有噪混合信号中高效提取降噪后的雷达信号及高质量的时频图,并通过iAMFF模块有效整合时频域TFA特征与时延-多普勒域的AFOS特征,从而为后续的信号分选提供了更加全面且具判别力的特征表达。经改进的DeepCluster聚类策略对高维特征表现出良好的适应性,进一步保障了雷达辐射源信号分选的准确性。

仿真实验结果表明,在 $\text{SNR} \in [-10, 10]$ dB的条件下,所提出的方法能够稳定实现雷达辐射源信号的有效分选,展现出一定的泛化能力、鲁棒性与稳定性。当 $\text{SNR} \geq 2$ dB时,模型分选准确率可达100%;即使在极端低SNR($\text{SNR} = -10$ dB)条件下,平均准确率仍保持在74.5%,优于当前主流方法,在实测雷达信号数据上的验证结果也进一步证明了该方法在真实复杂电磁环境中的实际应用潜力。下一步研究将继续探索多任务学习在RESS任务中的可拓展能力,通过任务模块化设计扩展更多应用场景,以提升复杂环境下雷达辐射源信号分选的效率与实用性。

参考文献:

- [1] ZHANG Z, SHI X, GUO X, et al. TR-RAGCN-AFF-RESS: A method for radar emitter signal sorting[J]. Remote Sensing, 2024, 16(7): 1121.
- [2] 刘凡, 袁伟杰, 原进宏, 等. 雷达通信频谱共享及一体化: 综述与展望[J]. 雷达学报, 2020, 10(3): 467-484.
LIU Fan, YUAN Weijie, YUAN Jinhong, et al. Spectrum sharing and integration of radar communication: Review and prospects[J]. Journal of Radars, 2020, 10(3): 467-484.
- [3] 隋金坪, 刘振, 刘丽, 等. 雷达辐射源信号分选研究进展[J]. 雷达学报, 2022, 11(3): 418-433.
SUI Jinping, LIU Zhen, LIU Li, et al. Research progress on radar emitter signal sorting[J]. Journal of Radars, 2022, 11(3): 418-433.
- [4] HU Z, LI H, TANG Z, et al. Radar signal recognition based on deep feature fusion of multiple time-frequency images[C]//Proceedings of 2023 International Conference on Wireless Communications and Signal Processing (WCSP). [S.l.]: IEEE, 2023: 377-383.
- [5] HESS-NIELSEN N, WICKERHAUSER M V. Wavelets and time-frequency analysis[J]. Proceedings of the IEEE, 1996, 84(4): 523-540.
- [6] 蒋闯. 基于改进VMD和TWSVM的雷达辐射源个体识别[J]. 信息技术与信息化, 2024(5): 101-106.
JIANG Chuang. Radar emitter individual identification based on improved VMD and TWSVM[J]. Information Technology and Informatization, 2024(5): 101-106.
- [7] 全大英, 唐泽雨, 陈赞, 等. 基于MSST及HOG特征提取的雷达辐射源信号识别[J]. 北京航空航天大学学报, 2022, 49(3): 538-547.
QUAN Daying, TANG Zeyu, CHEN Yun, et al. Radar emitter signal recognition based on MSST and HOG feature extraction[J]. Journal of Beijing University of Aeronautics and Astronautics, 2022, 49(3): 538-547.
- [8] 侯文太, 普运伟, 郭媛蒲, 等. 基于高斯平滑与模糊函数等高线的雷达辐射源信号分选[J]. 自动化学报, 2021, 47(10): 2484-2493.
HOU Wentai, PU Yunwei, GUO Yuanpu, et al. Radar emitter signal sorting based on Gaussian smoothing and fuzzy function contours[J]. Acta Automatica Sinica, 2021, 47(10): 2484-2493.
- [9] 战权海, 张雄伟, 宋磊, 等. 基于改进Transformer的自动调制识别方法[J]. 数据采集与处理, 2024, 39(6): 1410-1419.
ZHAN Quanhai, ZHANG Xiongwei, SONG Lei, et al. Automatic modulation recognition method based on improved Transformer[J]. Journal of Data Acquisition and Processing, 2024, 39(6): 1410-1419.
- [10] ALTIPARMAK F, AKYÖN F Ç, ÖZMEN E, et al. Towards cognitive sensing: Radar function classification using multitask learning[C]//Proceedings of 2019 27th Signal Processing and Communications Applications Conference (SIU). [S.l.]: IEEE, 2019: 1-4.
- [11] ZHANG Y, YANG Q. A survey on multi-task learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2021, 34(12): 5586-5609.
- [12] 李云峰, 闫祖龙, 高天, 等. 基于多任务学习的语音情感识别[J]. 数据采集与处理, 2024, 39(2): 424-432.

- LI Yunfeng, YAN Zulong, GAO Tian, et al. Speech emotion recognition based on multi-task learning[J]. *Journal of Data Acquisition and Processing*, 2024, 39(2): 424-432.
- [13] RUDER S. An overview of multi-task learning in deep neural networks[J]. *arXiv preprint arXiv:1706.05098*, 2017.
- [14] PAN P, ZHANG Y, DENG Z, et al. TFA-Net: A deep learning-based time-frequency analysis tool[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, 34(11): 9274-9286.
- [15] LI H, QUAN D, ZHOU F, et al. Radar signal recognition based on multi-task learning[J]. *IEEE Access*, 2024, 12: 153209-153220.
- [16] JIANG J, ZHENG L, LUO F, et al. RedNet: Residual encoder-decoder network for indoor RGB-D semantic segmentation[J]. *arXiv preprint arXiv:1806.01054*, 2018.
- [17] 普运伟,余永鹏,姜萤,等.基于多变换域特征的雷达辐射源信号融合识别[J/OL].*哈尔滨工业大学学报*,2026,58(3): 88-97.
PU Yunwei, YU Yongpeng, JIANG Ying, et al. Radar emitter signal fusion recognition based on multi-transform domain features[J/OL]. *Journal of Harbin Institute of Technology*, 2026,58(3): 88-97.
- [18] ZHANG Z, WAN C, CHEN Y, et al. Radar signal recognition based on CSRNN network[J]. *IEEE Access*, 2024, 12: 86704-86715.
- [19] HUYNH-THE T, DOAN V S, HUA C H, et al. Accurate LPI radar waveform recognition with CWD-TFA for deep convolutional network[J]. *IEEE Wireless Communications Letters*, 2021, 10(8): 1638-1642.
- [20] DU M, ZHONG P, CAI X, et al. DNCNet: Deep radar signal denoising and recognition[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2022, 58(4): 3549-3562.
- [21] ZHANG K, ZUO W, ZHANG L. FFDNet: Toward a fast and flexible solution for CNN-based image denoising[J]. *IEEE Transactions on Image Processing*, 2018, 27(9): 4608-4622.
- [22] ZHOU Y, JIAO J, HUANG H, et al. When AWGN-based denoiser meets real noises[C]//*Proceedings of the AAAI Conference on Artificial Intelligence*. [S.l.]: AAAI, 2020: 13074-13081.
- [23] KENDALL A, GAL Y, CIPOLLA R. Multi-task learning using uncertainty to weigh losses for scene geometry and semantics [C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.]: IEEE, 2018: 7482-7491.
- [24] 普运伟,陈新杰,余永鹏,等.基于模糊函数多维结构度量特征的雷达辐射源信号流在线分选[J].*仪器仪表学报*,2023,44(8): 277-288.
PU Yunwei, CHEN Xinjie, YU Yongpeng, et al. Online sorting of radar emitter signal stream based on multidimensional structural measurement characteristics of fuzzy function[J]. *Chinese Journal of Scientific Instrument*, 2023, 44(8): 277-288.
- [25] 普运伟,郭江,刘涛涛,等.基于多学习单元卷积神经网络的雷达辐射源信号识别[J].*北京邮电大学学报*,2021,44(6): 74-82.
PU Yunwei, GUO Jiang, LIU Taotao, et al. Radar emitter signal recognition based on multi-learning unit convolutional neural network[J]. *Journal of Beijing University of Posts and Telecommunications*, 2021, 44(6): 74-82.
- [26] DAI Y, GIESEKE F, OEHMCKE S, et al. Attentional feature fusion[C]//*Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision*. [S.l.]: IEEE, 2021: 3560-3569.


作者简介:



普运伟(1972-),通信作者,男,教授,博士生导师,研究方向:智能信息处理、教育智能化, E-mail: puyunwei@126.com。



赵辉杰(1997-),男,硕士研究生,研究方向:智能信息处理。



李文康(2001-),男,硕士研究生,研究方向:智能信息处理。



田春瑾(1978-),女,博士,副教授,研究方向:智能信息处理、教育智能化。

(编辑:陈琚)

A Radar Emitter Signal Sorting Method Based on Multi-task Learning and Multi-domain Feature Fusion

PU Yunwei^{1,2*}, ZHAO Huijie¹, LI Wenkang¹, TIAN Chunjin¹

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

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

Abstract: Radar emitter signal sorting (RESS) plays a critical role on modern electronic warfare. To address the limitations of traditional sorting methods, such as low efficiency and limited accuracy in complex electromagnetic environments, as well as radar-communication spectrum sharing (RCSS) brought about by the development of 5G communication technologies, this paper proposes an innovative solution based on multi-task learning and multi-domain feature fusion. First, the proposed method constructs a multi-task learning (MTL) framework to jointly preprocess noisy radar-communication mixed signals, including signal cleansing, denoising, and time-frequency feature enhancement. Second, a feature fusion network is designed to extract multi-scale features from both the time-frequency image domain and the time-delay-Doppler domain. An improved iterative attention mechanism is employed to achieve cross-domain feature fusion, resulting in a high-dimensional feature representation with a strong discriminative power. Finally, a clustering model based on DeepCluster is used to accurately sort radar emitter signals. Experiments demonstrate that under low signal-to-noise ratio (SNR) condition of -6 dB, the proposed method effectively suppresses communication signal interference and achieves a sorting accuracy of 93.8%. Compared with existing approaches, the proposed solution demonstrates significant advantages in enhancing the robustness of signal preprocessing and maintaining high sorting accuracy, underscoring its strong potential for practical engineering applications.

Highlights:

1. A signal collaborative preprocessing model based on multi-task learning is constructed, integrating signal feature enhancement, cleaning, and denoising into a unified framework for joint optimization.
2. A multi-domain feature fusion model based on an iterative attention mechanism is developed, exploiting the complementarity of time-frequency image features and ambiguity function orthogonal slice features to form a highly discriminative joint representation.
3. An improved DeepCluster clustering method is proposed, combining supervised pre-training, semi-supervised training, and supervised fine-tuning to achieve both strong generalization and high accuracy, effectively enhancing sorting performance.

Key words: radar emitter signal sorting (RESS); radar-communication spectrum sharing (RCSS); deep learning (DL); multi-task learning (MTL); attention mechanism