

先验引导的轻量化噪声鲁棒雷达复合干扰多标签识别网络

赵云飞 刘梅 高勋章* 刘烁炜

(国防科技大学电子科学学院 长沙 410073)

摘要: 干扰辨识是提升雷达目标识别系统抗干扰能力的关键环节。相较于单一干扰,复合干扰由于结构复杂、组合形式灵活,其辨识难度显著增加。然而,现有辨识方法大多为数据驱动模型,未引入干扰的先验信息,导致模型在复杂场景下存在性能瓶颈,且可解释性不足;同时,大多方法缺乏噪声抑制机制,在复杂环境下易出现噪声过拟合问题。为此,该文基于不同干扰在时域上的对称性数学先验,提出了一种干扰先验引导的噪声鲁棒雷达复合干扰多标签识别网络。首先,通过由粗到细去噪的策略对复合干扰进行噪声抑制,并优化干扰的先验结构,缓解辨识过程中由噪声引起的过拟合问题;其次,计算自相关对称性得分量化干扰先验强度,并通过对称编码器,将先验强度映射为门控机制,引导干扰特征融合并时序建模;最后,将噪声强度与时序特征联合嵌入到识别网络中,进一步增强模型在不同信噪比条件下的鲁棒性。实验表明,在低信噪比条件下,所提方法对15种间歇采样转发复合干扰和30种复杂复合干扰的平均识别准确率均超过90%,在性能优于最优对比模型的同时,显著降低了模型参数量。

关键词: 雷达复合干扰; 多标签分类; 特征融合; 干扰识别; 小波分解; 噪声抑制

中图分类号: TN958

文献标识码: A

文章编号: 2095-283X(2026)x-0001-16

DOI: 10.12000/JR25272

CSTR: 32380.14.JR25272

引用格式: 赵云飞, 刘梅, 高勋章, 等. 先验引导的轻量化噪声鲁棒雷达复合干扰多标签识别网络[J]. 雷达学报(中英文), 待出版. doi: 10.12000/JR25272.

Reference format: ZHAO Yunfei, LIU Mei, GAO Xunzhang, *et al.* Prior-guided lightweight noise-robust multi-label radar composite interference recognition network[J]. *Journal of Radars*, in press. doi: 10.12000/JR25272.

Prior-guided Lightweight Noise-robust Multi-label Radar Composite Interference Recognition Network

ZHAO Yunfei LIU Mei GAO Xunzhang* LIU Shuowei

(College of Electronic Science and Technology, National University of Defense Technology,
Changsha 410073, China)

Abstract: Interference identification is a critical component in enhancing the anti-jamming capability of radar target recognition systems. Compared with single-type interference, composite interference poses substantially greater identification challenges due to its structural complexity and flexible combination patterns. However, most existing identification methods are purely data-driven and fail to incorporate interference prior knowledge, resulting in performance bottlenecks in complex scenarios and limited interpretability. Moreover, many approaches lack effective noise suppression mechanisms and are prone to noise overfitting under low Signal-to-Noise Ratio (SNR) conditions. To address these limitations, this study proposes a prior-guided, noise-robust

收稿日期: 2025-12-17; 改回日期: 2026-03-05; 网络出版: 2026-04-15

*通信作者: 高勋章 gaoxunzhang@nudt.edu.cn *Corresponding Author: GAO Xunzhang, gaoxunzhang@nudt.edu.cn

基金项目: 国家自然科学基金(61921001), 湖南省研究生创新项目(CX20250020)

Foundation Items: The National Natural Science Foundation of China (61921001), The Hunan Provincial Graduate Student Research Innovation Program (CX20250020)

责任主编: 李亚超 Corresponding Editor: LI Yachao

©The Author(s) 2026. This is an open access article under the CC-BY 4.0 License
(<https://creativecommons.org/licenses/by/4.0/>)

multi-label recognition network for radar composite interference, which exploits time-domain symmetry priors in different interference types. First, a coarse-to-fine denoising strategy is employed to suppress noise while preserving and enhancing their prior structural characteristics, thereby alleviating noise-induced overfitting during the recognition process. Second, an autocorrelation-based symmetry score is introduced to quantify the strength of the interference prior. The score is then mapped into a gating mechanism via a symmetry encoder to guide interference feature fusion and temporal representation learning. Finally, noise intensity and temporal features are jointly embedded into the recognition network, further enhancing the robustness of the proposed method across varying SNR conditions. Experimental results demonstrate that, under low-SNR conditions, the proposed method achieves average recognition accuracies exceeding 90% for 15 types of intermittent sampling repeater composite interference and 30 types of complex composite interference. Moreover, the proposed approach outperforms the strongest baseline model while significantly reducing model parameters.

Key words: Radar composite jamming; Multi-label classification; Feature fusion; Jamming signal recognition; Wavelet decomposition; Noise Suppression

1 引言

近年来,基于数字射频存储技术(Digital Radio Frequency Memory, DRFM)的新型雷达有源干扰技术给雷达干扰识别带来了极大挑战^[1]。例如,间歇采样转发干扰(Interrupted-Sampling Repeater Jamming, ISRJ)通过对雷达信号进行快速采样并转发,显著增强了干扰信号与雷达信号之间的相干性,提升了干扰的欺骗效果^[2]。为进一步优化干扰特征,研究者通过将间歇采样技术与其他干扰调制方法相结合,发展出多种调制方式的组合干扰,此类干扰融合了多种信号调制的特征,使得干扰信号形态更加多样。在现代电子战中,敌方常采用多干扰机协同工作,干扰信号中存在多个不同来源的干扰,进一步增加了雷达干扰识别的难度^[3-5]。与传统的噪声压制、距离门拖引等干扰相比,基于DRFM的各类组合型复合干扰应用更广,欺骗能力更强,对雷达识别的影响更大。因此,现代雷达干扰识别的研究重点正从传统的单一干扰识别转向对这类新型复合干扰的精确辨识与有效对抗^[6,7]。

在雷达干扰识别领域,现有研究大多仍在单一干扰场景下展开,整体可分为两类方法。一类方法通过提取干扰信号在时域、频域或时频域的统计特征,构建人工设计的特征向量实现干扰识别^[7,8],如Hao等人^[9]通过结合时域与频域的分形维数特征以及时频域的雷尼熵特征,并利用多类支持向量机实现雷达干扰信号的识别,Shi等人^[10]通过核密度估计获得样本近似的特征条件概率,并构建朴素贝叶斯分类器,实现干扰识别,刘一兵等人^[11]通过提取干扰多维小波特征向量,计算不同尺度下小波系数的移位相关系数,并实现干扰识别。然而,这类方法的特征建模主要依赖于信号的统计特性,且特征选择高度依赖人工经验,导致在复合干扰等复杂场

景下识别准确率明显下降^[7,12]。另一类方法则通过深度学习,提升特征自动提取与识别性能。例如,Zhao等人^[13]采用改进的LeNet网络增强雷达干扰识别效果,Lin等人^[14]基于递归图和卷积神经网络(Convolutional Neural Network, CNN)实现了ISRJ干扰的有效识别;Wu等人^[15]利用短时傅里叶变换将干扰信号和目标回波转换为时频图像,并基于UNet-A结构进行像素级分割,成功实现了目标与ISRJ干扰区域的精细划分。尽管这些方法在单一干扰场景下取得了较好效果,但其网络结构和训练范式多是针对单一干扰场景设计,直接推广至复合干扰识别时准确率会大幅下降。

基于此,近年来部分学者开始面向复合干扰场景开展研究,通过多域深层特征分析提升复合干扰的可分性。例如,Zhou等人^[16]利用变分模态分解提取欺骗干扰的时域和频域深层分量特征,实现了对部分传统复合干扰的识别,Zhou等人^[17]利用分数阶傅里叶变换和注意力机制对复合干扰进行辨识,然而这类方法主要针对简单组合的雷达复合干扰,并采用单分类学习架构,在复合干扰种类过多时易产生学习时间长、标签爆炸的问题。相比之下,Zhu等人^[18]基于多标签卷积神经网络(Multi-Label Convolutional Neural Network, MLCNN),以时频图像为输入,提出了MLACM网络,实现了复合干扰的多标签分类,Qu等^[19]将一维功率谱重构为二维图像并提出JRNet,用以识别4类单一压制干扰与6类复合压制干扰,具有较强的压制复合干扰模式识别能力,Lv等人^[20]通过设置混合注意力机制并基于ShuffleNet-v2提出了一种轻量化多标签识别网络,实现了多种复合干扰的多标签识别。

在复合干扰识别方面,现有方法虽已取得一定进展,但仍存在一些共性问题。其一,现有网络在设计时未充分利用干扰信号的数学先验,主要依赖

数据驱动进行特征学习, 可解释性和泛化能力均受到限制, 需通过先验信息引导网络学习缓解这一现象^[21]。其二, 现有方法普遍缺乏面向干扰结构的噪声抑制机制, 在强噪声背景下, 雷达距离像特征容易被噪声淹没, 导致干扰类间差异减弱、类内差异增大, 从而显著降低识别精度^[22]。其三, 现有多数方法高度依赖时频图进行特征提取, 而时频图数据维度高、冗余特征多, 导致网络参数量庞大, 在有限样本和低信噪比条件下极易发生过拟合, 难以兼顾战场环境对实时性与模型轻量化的要求, 鉴于此, 本文提出了先验引导的轻量化噪声鲁棒雷达复合干扰多标签识别网络, 引入了针对干扰结构的噪声抑制机制, 缓解模型过拟合现象; 并使用干扰先验引导对称编码器学习不同复合干扰的特征, 同时, 所提网络仅基于一维数据进行特征提取, 有效降低了模型复杂度。本文的主要贡献如下:

(1) 设计了基于干扰数学先验的复合干扰多标签识别网络。针对不同干扰的先验知识, 设计结构可解释的复合干扰多标签识别网络, 利用结构先验引导特征学习, 提升特征可分性与模型可解释性。

(2) 在噪声抑制的基础上对干扰先验进行加强。针对低信噪比场景下复合干扰特征可分性下降的问题, 利用去噪网络进行噪声抑制; 进一步结合先验特征优化分支增强干扰先验, 实现低信噪比条件下的稳健特征提取。

(3) 融合了时域与小波分解域特征实现高效时序建模。小波分解兼具时频分辨能力, 对噪声具有较强的鲁棒性^[23], 适用于时序信号的高频纹理提取^[24,25], 针对不同类型的雷达干扰可得到不同数学特性的分解结果。因此, 本文将小波分解细节系数与时域对称编码特征进行拼接, 并送入时序建模网络捕获高精度时序特征, 提升干扰辨识效果。

2 雷达干扰的数学特征分析

2.1 干扰时域数学特征分析

2.1.1 间歇采样转发干扰

间歇采样转发干扰通过对雷达发射信号进行间歇采样、存储和再转发, 生成与真实目标高度相关的多假目标干扰, 主要分为间歇采样直接转发干扰(Interrupted-Sampling Discrete Jamming, ISDJ)和间歇采样重复转发干扰(Interrupted-Sampling Periodic Jamming, ISPJ)^[26,27], ISDJ仅对采样信号进行一次放大并转发, 其时域模型为

$$s_{\text{ISDJ}}(t) = A \sum_{h=0}^H \text{rect} \left(\frac{t - (2h+1)T_J}{T_J} \right) s(t - T_J) \quad (1)$$

其中, H 为采样次数, T_J 为采样宽度, A 为放大系数, $\text{rect}(\cdot)$ 为矩形窗函数, $s(t)$ 为雷达发射信号。

ISPJ则对采样信号进行多次放大、复制并转发, 形成周期性的多假目标, 其时域模型为

$$s_{\text{ISPJ}}(t) = A \sum_{h=1}^H \sum_{n=1}^{N_1} \text{rect} \left(\frac{t - \alpha(h,n)T_J}{T_J} \right) s(t - nT_J) \quad (2)$$

其中, N_1 表示转发次数, $\alpha(h,n) = (h-1)(N_1+1) + n$ 为延迟系数。

由式(1)和式(2)可知, ISDJ脉压后会产生近似 sinc 函数分布的对称多假目标, 而 ISPJ 脉压后会生成等间隔、周期性出现的假目标群, 且各群内部同样保持对称分布。

间歇采样卷积调制转发干扰(Smart Noise Interrupted Sampling Repeater Jamming, SNISRJ)通过将 ISRJ 干扰与灵巧噪声卷积, 增强了干扰信号的随机性与欺骗效果。通过调节卷积参数与发射功率, 可实现偏重欺骗的 SNISRJ-1 和偏重压制的 SNISRJ-2 两类模式^[28], SNISRJ 干扰表达式为

$$s_{\text{SNISRJ}}(t) = \sum_{i=0}^{N_1-1} \left\{ \frac{T_J}{T_s} \sum_{l=0}^{L-1} A_{ly} \left(t + iT_J - \sum_{j=0}^l t_j \right) + \frac{2T_J}{T_s} \left(\sum_{n=1}^{\infty} \frac{\sin(n\pi f_s T_J)}{n\pi f_s T_J} \right) \cos(2\pi n f_s T_J) \cdot \sum_{l=0}^{L-1} A_{ly} \left(t + iT_J - \sum_{j=0}^l t_j \right) \right\} \quad (3)$$

其中, T_s 为采样周期, f_s 为采样频率, A_l 为随机幅值, t_j 为随机采样间隔, L 为随机参量的个数。

由式(3)可见, 当噪声序列较短时, 卷积对 ISRJ 的影响有限, 干扰仍呈现准周期、准对称的结构, 仅出现轻微随机扰动, 形成欺骗型干扰; 当噪声序列较长时, 卷积对干扰特征影响显著, 各转发分量相互叠加, 使得原有的时序特征消失, 呈现压制干扰的特性。

2.1.2 其他典型雷达干扰的时域特征

切片重组干扰(Chopping & Interleaving, C&I)通过将接收的雷达信号按时间进行截取, 提取等间隔脉冲, 随后对其进行时移填充与叠加, 重构出连续完整的时域干扰信号, 经脉压处理后形成多假目标欺骗干扰:

$$s_{\text{C&I}}(t) = A \sum_{k=0}^{N_2-1} \sum_{i=0}^{M_1-1} s \left(t - \frac{kT}{M_1 N_2} \right) \cdot \left[u \left(t - \frac{iT}{M_1} \right) - u \left(t - \frac{iT}{M_1} - \frac{T}{N_2} \right) \right] \quad (4)$$

其中, $u(\cdot)$ 表示单位阶跃函数, T 表示雷达脉宽, M_1 表示截取阶段划分的子脉冲个数, N_2 表示交织阶段时移叠加的时隙数量。

梳状谱干扰(Comb Spectrum Modulation Jamming, COMB)通过在信号带宽内生成多条等间隔或随机分布的谱线, 与原始截获信号进行调制, 产生具有梳状频谱特征的干扰, 利用多条谱线的叠加效应, 产生欺骗或压制干扰^[3]:

$$s_{\text{COMB}}(t) = A s(t) \sum_{i=1}^{M_2} a_i \exp(j2\pi f_i t) \quad (5)$$

其中, M_2 表示谱线数量, $f_i = f_0 + (i-1)\Delta f$ 为第*i*条谱线的频率, a_i 为第*i*条谱线随机幅度因子。

频谱弥散干扰(Spread Modulated Spectrum Perturbation, SMSP), 通过将截获的雷达信号分解为多个时间片段, 并引入频率、相位等参数的扰动, 使干扰信号的频谱能量在目标带宽内充分弥散, 形成压制干扰:

$$s_{\text{SMSP}}(t) = A \sum_{m=1}^{M_3} \exp\left(j2\pi \left[f_m t + \frac{k_m t^2}{2} \right]\right), \quad t \in \left[\frac{(m-1)T}{M_3}, \frac{mT}{M_3} \right] \quad (6)$$

其中, M_3 表示信号切片的段数, $T_m = T/M_3$ 为每段的时宽, $f_m = f_c + (m-1)K$ 为第*m*段的载波频率, K 为频率步长, $k_m = B/T_m$ 为第*m*段的调频斜率。

噪声卷积干扰(Noise Convolution Jamming, NCJ)通过将截获的雷达信号与噪声核函数进行时域卷积,

使信号的脉冲宽度扩展, 卷积后的干扰信号具有噪声的随机性, 脉冲压缩后在距离向产生压制干扰:

$$s_{\text{NCJ}}(t) = A [s(t) \otimes w(t)] \quad (7)$$

其中, \otimes 表示卷积运算, $w(t)$ 为噪声卷积核。

图1展示了4种间歇采样转发干扰和C&I, COMB, SMSP, NCJ雷达干扰的脉压特征。与理论分析一致, ISRJ欺骗干扰大多具有不同的对称性特征, 而C&I和COMB在用作欺骗干扰时整体上虽不具备严格的对称性, 但受雷达脉压处理的影响, 其生成的各个子假目标脉冲在局部范围内仍表现出对称结构, 仅在距离维度上存在一定的偏移和幅值差异。在压制干扰中, SMSP干扰由大量小脉冲构成, 其叠加效应使干扰能量在时域和频域上均呈现出宽带弥散特性; 相比之下, NCJ的对称性特征相对较弱, 其时域分布更为随机。因此, 不同干扰的时域对称性特征与时序结构方面表现出明显差异, 可针对性设计网络架构, 实现对多种干扰的区分。

2.2 干扰小波分解系数数学特征

雷达干扰信号通常表现出显著的非平稳特性, 其时频结构随时间动态变化。小波分解能够在时域与频域上同时实现局部化分析, 具有良好的抑噪能力, 可提取信号的细节纹理信息^[29]。因此, 可将小波细节分解系数作为辅助信息送入网络学习, 提升干扰识别的准确性, 对离散信号 $x[n]$, 其小波分解后的第*j*层的近似系数 \mathbf{cA}_j 与细节系数 \mathbf{cD}_j 可通过滤波和下采样获得

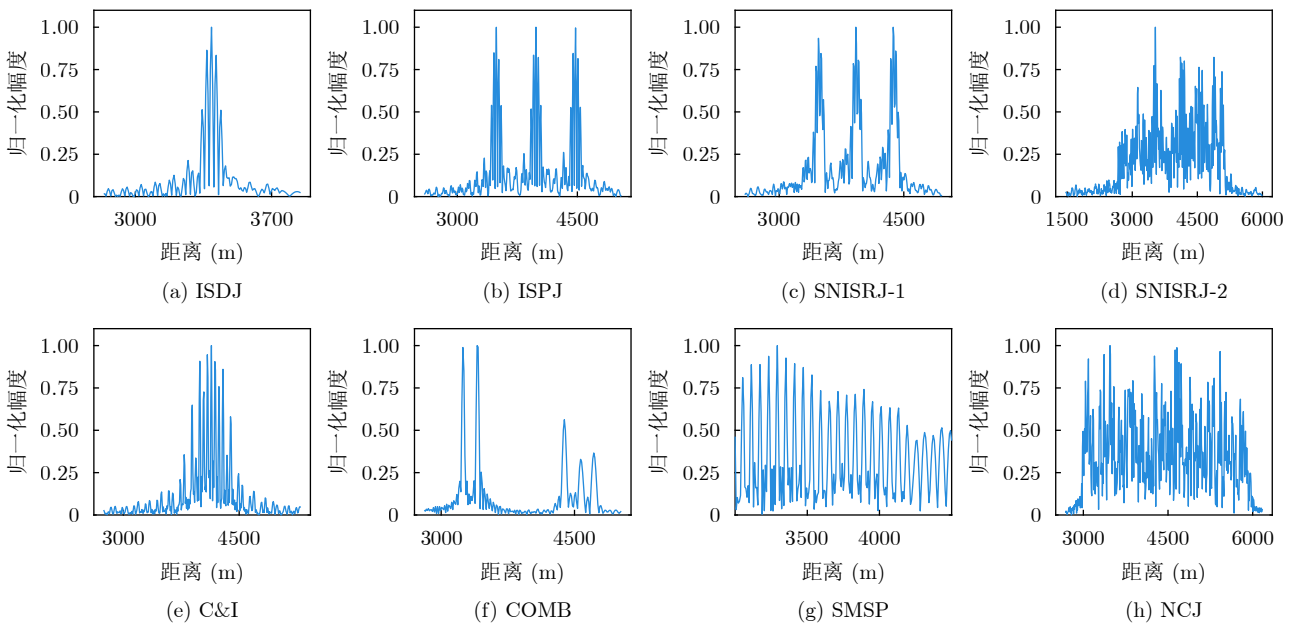


图1 8种干扰模型脉压结果图

Fig. 1 Eight types of interference model pulse compression results

$$\begin{aligned} \mathbf{cA}_j &= \sum_n x[n] \cdot h[2k-n], \\ \mathbf{cD}_j &= \sum_n x[n] \cdot g[2k-n] \end{aligned} \quad (8)$$

其中, $h[n]$ 与 $g[n]$ 分别为低通与高通滤波器, 对应尺度与细节系数。

从数学角度看, 近似系数 \mathbf{cA}_j 主要反映信号的低频包络信息, 而细节系数 \mathbf{cD}_j 主要反映高频突变与纹理信息。因此, 不同类型干扰的小波细节系数会展现出可区分的结构特征。

针对ISDJ干扰, 由于ISDJ中的假目标关于主假目标呈中心对称分布, 因此每个干扰在数学上可表示为 $f[n_0+k_0]=f[n_0-k_0]$, k_0 为对称中心, ISDJ的小波分解的细节系数 \mathbf{cD}_j 可表示为

$$\mathbf{cD}_j[k] = \sum_n f[n]g[n-2k] \quad (9)$$

同时, 由于小波细节滤波器具有近似反对称性 $g[p] = -g[L-1-p]$, 由此可推导出ISDJ的小波分解细节系数满足近似奇函数对称性:

$$\mathbf{cD}_j[-k] = -\mathbf{cD}_j[k] \quad (10)$$

对于ISPJ干扰, 由于其产生机理是对ISDJ干扰进行周期性延拓, 因此其小波分解所得的细节系数在各个周期段均表现出近似奇对称特性, 呈现周期性的分布。针对欺骗型SNISRJ-1干扰, 由于随机噪声对信号形状影响有限, 细节系数仍近似呈现奇函数特性, 仅存在轻微随机扰动。相比之下, 压

制型SNISRJ-2干扰由于噪声对信号形状的影响显著, 干扰的结构特性发生了较大变化。经小波分解后, 细节系数的峰值位置和幅度呈现出明显的非均匀统计特征, 干扰信号在不同尺度上的变化失去了原有的规则性和结构性。

对于剩余4类干扰(C&I, COMB, SMSP, NCJ), 虽然这些干扰的整体对称性不明显, 小波细节系数的奇函数对称特性表现较差, 但这些干扰在距离维度上的分布特征各不相同, 因此, 其小波细节分解系数的峰值位置、能量分布均呈现出特有的纹理特征, 同样可作为区分不同非对称干扰类型的有效表征。

图2展示了各类干扰第1层小波分解归一化后细节系数 \mathbf{cD}_1 的特征, 小波基函数为db10。可见不同干扰的小波分解系数具有不同的纹理信息, 将这些信息送入网络能够有效地辅助后续模型进行特征提取, 提升不同干扰的识别效果。

3 先验引导的轻量化噪声鲁棒雷达复合干扰多标签识别网络

本文提出的网络架构如图3所示, 首先, 噪声抑制与特征优化模块利用残差去噪网络抑制干扰噪声, 并通过对称性与周期性特征优化分支强化先验结构; 随后, 特征编码与时序建模模块引入干扰对称性先验, 将干扰数学特征转化为网络内部的门控机制, 引导网络使用对称编码器提取干扰对称信息, 同时引入一阶小波分解得到的细节分量作为辅助特征, 与对称编码特征进行融合并完成时序建

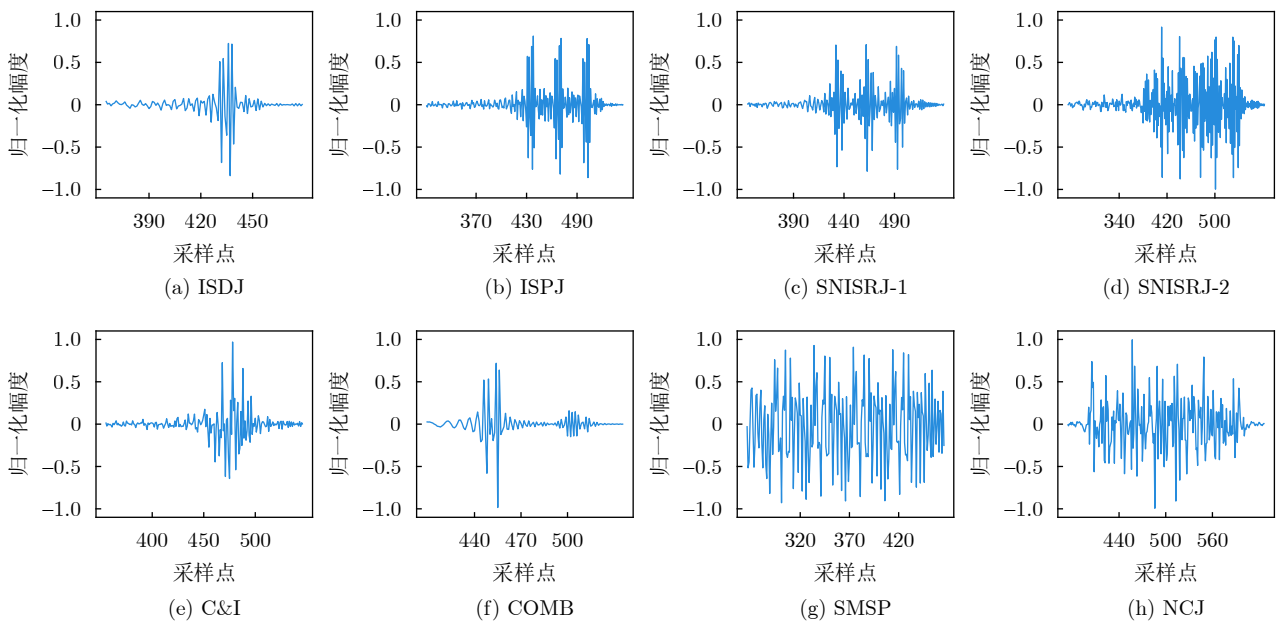


图2 小波细节系数特征图

Fig. 2 Wavelet detail coefficient feature map

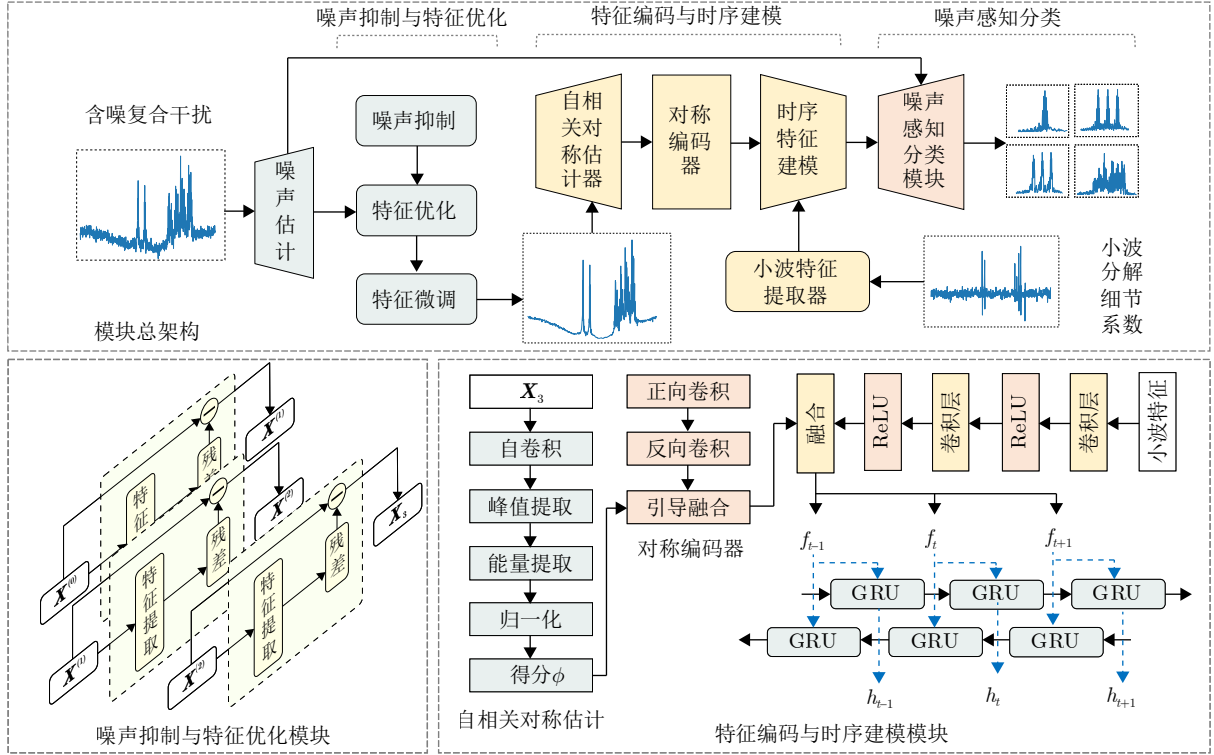


图3 本文网络结构示意图

Fig. 3 Schematic of the proposed network

模；最后，噪声感知分类模块将噪声强度融入时序特征，补充去噪模块损失的噪声强度信息，实现噪声感知的复合干扰多标签分类。

3.1 噪声抑制与特征优化模块

为了在噪声环境下有效保护并提取干扰信号的先验结构，本模块将对复合干扰信号进行噪声抑制与特征优化。模块结构如图4所示，通过噪声抑制、先验残差去除及特征微调3个步骤，由粗到细地实现去噪与先验结构强化。

首先，利用基于残差学习的粗去噪网络(Cascaded Denoising Network, CDN)预测复合干扰中的噪声残差分量，并通过残差相减的方式粗略去除信号中的大幅度噪声，从而减轻模型对噪声的过拟合问题^[30,31]：

$$\mathbf{X}^{(1)} = \mathbf{X}^{(0)} - \text{CDN}(\mathbf{X}^{(0)}) \quad (11)$$

其中， $\mathbf{X}^{(0)}$ 为原始干扰信号， $\mathbf{X}^{(1)}$ 为粗去噪信号。

然后，利用先验结构特征优化网络(Feature Optimization Network, FON)增强先验特征。该网络包含对称性与周期性两条优化分支，旨在定位并去除破坏先验结构的噪声及无关分量，保留干扰在时域上的先验特征。

对称性分支通过计算前向卷积特征 \mathbf{F}_1 与反转卷积特征 \mathbf{F}_2 ，利用余弦相似度构建掩码 Mask_{sym} ，

基于掩码，网络对双向特征进行加权，提取破坏对称性先验的残差：

$$\text{Mask}_{\text{sym}} = \sigma \left(\frac{\mathbf{F}_1 \cdot \mathbf{F}_2}{\|\mathbf{F}_1\| \|\mathbf{F}_2\|} \right) \quad (12)$$

其中， $\|\cdot\|$ 表示二范数， σ 表示Sigmoid激活函数。

周期性优化分支采用多尺度卷积结构捕捉不同的周期模式，将检测结果拼接后，通过周期性增强器强化不稳定的周期成分，并与周期一致性得分逐元素相乘，从而提取出与周期先验无关的残差。

为在不同噪声条件下有效融合两路分支的输出，并提升模块的噪声感知能力，利用信号时序差分估计高频噪声强度：

$$n_{\text{esm}} = \sigma \left(G \left(|\nabla_t \mathbf{X}^{(0)}| \right) \right) \quad (13)$$

其中， $G(\cdot)$ 表示由全局平均池化与逐层卷积构成的网络， $\nabla_t \mathbf{X}^{(0)}[t] = \mathbf{X}^{(0)}[t+1] - \mathbf{X}^{(0)}[t]$ 为差分算子。

随后，将噪声估计强度 n 输入两层全连接的自适应权重网络(Adaptive Weight, AW)，得到两路分支的权重， $[\omega_{\text{sym}}, \omega_{\text{per}}]^T = \text{softmax}(\text{AW}(n_{\text{esm}}))$ ，从而实现不同噪声条件下两路分支特征的自适应融合。融合后的特征经轻量卷积映射得到总的无关残差，通过与粗去噪信号残差相减得到特征优化信号： $\mathbf{X}^{(2)} = \mathbf{X}^{(1)} - \text{FON}(\mathbf{X}^{(1)})$ ，从而去除与对称和周期先验无关的成分，保留结构一致的特征。

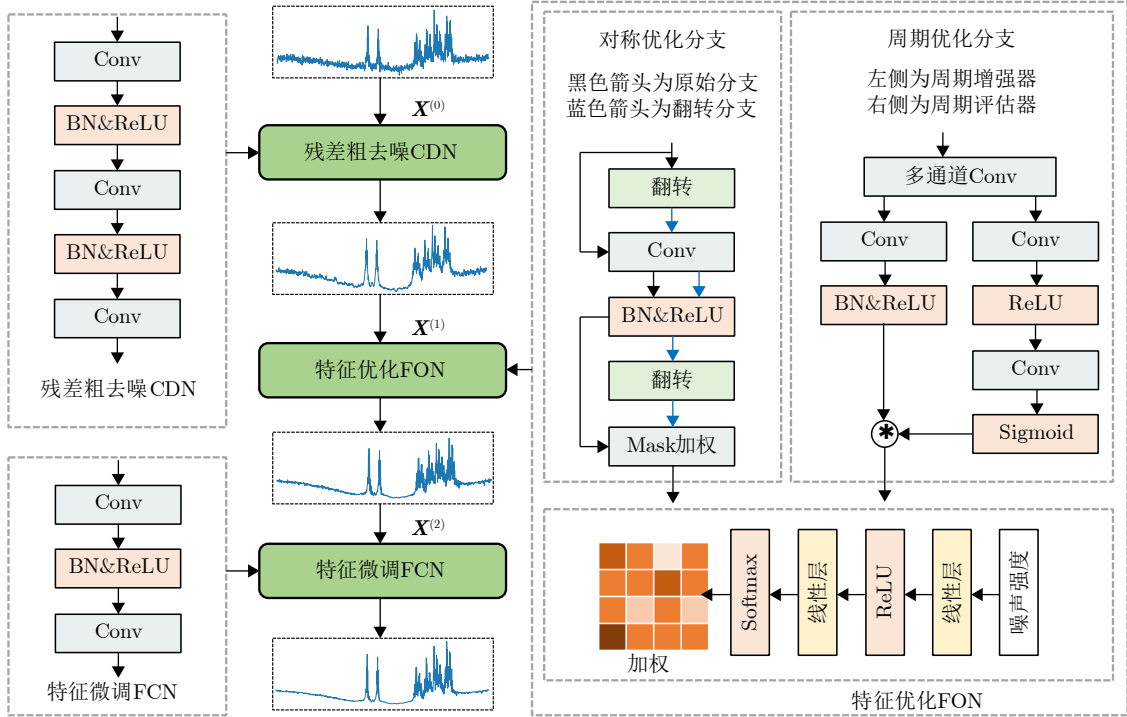


图 4 噪声抑制与特征优化模块结构图

Fig. 4 Architecture of the noise suppression and feature optimization module

最后，特征微调网络(Feature Calibration Network, FCN)通过小感受野卷积进一步提取细粒度噪声成分，进行残差相减，获得最终的噪声抑制与特征优化特征 X_3 ：

$$X_3 = X^{(2)} - \text{FCN}(X^{(2)}) \quad (14)$$

3.2 对称编码与时序建模模块

针对传统干扰辨识网络依赖隐式统计特征、物理可解释性和泛化能力不足的问题，本文提出一种先验引导的对称编码与时序建模模块。该模块通过显式引入干扰信号的时间对称性先验，将干扰数学特征转化为网络内部的门控机制，从而实现物理先验与深度特征学习的融合，提升模型在复杂干扰环境下的泛化能力与可解释性。

首先，构建自相关对称性得分 ϕ 作为先验引导门控。不同于可学习的神经网络参数， ϕ 基于自相关理论，通过计算信号与其时间反转序列的自卷积峰值，并进行能量归一化，定量刻画干扰信号的时间对称程度，其定义为

$$\phi = \frac{\max[\mathcal{F}^{-1}(|\mathcal{F}(\mathbf{X})|^2)]}{\|\mathbf{X}\|_2^2} \quad (15)$$

其中， \mathcal{F} 表示快速傅里叶变换， \mathcal{F}^{-1} 表示快速傅里叶逆变换， \max 表示取非零延迟下的最大值。

在此基础上，设计了对称编码器以实现先验引导的特征提取，编码器采用前向与反向双路卷积结构，

其中前向路径提取干扰信号的常规时序特征 F_{fwd} ，反向路径通过时间翻转卷积捕获其对称结构特征 F_{bwd} ，并使用干扰信号的对称性得分 ϕ 作为门控因子，对反向特征流进行自适应加权，形成对称增强特征表示：

$$F_{\text{sym}} = F_{\text{fwd}} \oplus (\phi \cdot F_{\text{bwd}}) \quad (16)$$

其中， \oplus 表示特征拼接操作。

当干扰信号具有显著对称结构时 ($\phi \rightarrow 1$)，模型增强反向路径的信息注入；当对称性因噪声过强或复合干扰时域重合过多退化时，门控机制自动抑制镜像特征的干扰，从而避免伪结构对判别结果的负面影响，提高特征空间的稳定性。进一步地，为补充不同干扰信号的高频纹理信息，模块引入一阶小波分解得到的细节分量作为辅助特征，与对称编码特征进行多通道融合，融合后的特征序列送入双向门控循环单元以建模干扰信号的非平稳时序关系，最终通过全局平均池化对时序状态进行聚合，获得时序判别特征向量 F_{tem} ，用于后续干扰识别。

3.3 噪声感知分类模块

在完成对称先验引导的时序特征提取与建模后，噪声感知分类模块将进一步建立深度特征空间与先验信息之间的融合。不同于传统分类器仅依赖隐式学习的高维特征表示，本文通过将时序判别特征、噪声强度、对称先验直接嵌入分类器决策向量，使模型具备对先验差异的自适应判决能力：

$$\mathbf{F}_{\text{dec}} = [\mathbf{F}_{\text{tem}} \oplus n_{\text{esm}} \oplus \phi] \quad (17)$$

其中, \mathbf{F}_{tem} 为经对称编码与时序建模得到的时序特征, n_{esm} 为噪声估计网络输出的噪声水平, ϕ 为基于自相关分析得到的对称性置信度。

分类器采用轻量化全连接网络实现非线性判别映射, 其结构参数如表1所示, 通过将噪声水平 n_{esm} 与对称性得分 ϕ 作为独立先验变量输入判别函数, 分类器能够在不同信噪比条件和结构可信度水平下, 自适应调整各干扰类别在特征空间中的判别权重与分布形态。当观测信号处于低信噪比或对称结构退化状态时, 分类器将更多依赖稳健时序特征进行判决; 而在高信噪比且物理结构清晰的条件下, 先验信息可有效强化类别区分能力。避免了复杂环境下先验失效带来的性能退化, 从而提升模型在复合干扰识别任务中的稳定性。

4 实验结果和分析

为满足复合干扰生成的机理, 有效模拟不同干扰源在信号接收中的相互叠加, 本文采用加性复合干扰信号生成方法和多标签标注方法构建复合干扰数据集^[6,18], 能够模拟不同干扰源在信号接收和脉压后的时间和频率域中的重叠特性:

$$S(t) = \sum_{i=1}^J w_i h_i(t) + N(t) \quad (18)$$

其中, $S(t)$ 表示复合干扰信号, w_i 为每种干扰的权重系数, $h_i(t)$ 为第*i*种干扰信号; $N(t)$ 为噪声。

本文共构建了3个数据集用于模型性能评估。数据集1包含4类具有较强欺骗性和随机性的ISRJ干扰信号, 分别为ISDJ, ISPJ, SNISRJ-1和SNISRJ-2, 并在此基础上组合生成15种复合干扰信号, 用以测试模型在新型复合干扰场景下的辨识能力。数据集2由5种不同类型的干扰信号构成, 包括ISRJ, SMSP, NCJ, C&I和COMB, 并进一步组合生成30种复合干扰信号, 用于评估模型在复杂复合干扰条件下的泛化能力。数据集3同样包含上述5类干扰信号, 但在生成复合干扰时偏离训练集干扰参数生成30种参数失配的复合干扰信号, 以测试模型在干

表1 噪声感知分类器结构

Tab. 1 Noise-aware classifier architecture

层	操作	输出形状
输入	\mathbf{F}_{dec}	(B,24+2)
1	线性层26→64, ReLU	(B,64)
2	Dropout ($p=0.3$)	(B,64)
3	线性层64→32, ReLU	(B,32)
4	线性层32→分类数	(B, 分类数)

扰参数变化条件下的鲁棒性与泛化能力。各数据集的干扰参数配置如表2所示, 雷达发射机参数均相同, 数据集3给出了具体的参数失配情况, 其余参数与数据集2相同。

随后, 对于生成的复合干扰信号, 本文采用了二值多标签标注策略。为每个信号样本 \mathbf{S} 分配一个二值标签向量 \mathbf{Y} , 用于标明信号中是否包含特定类型的干扰。具体来说, 标注向量 \mathbf{Y} 由若干示性函数 $\mathbb{I}(\cdot)$ 组成, 其中每个示性函数对应一个干扰类型的标签, 表示信号中是否存在该干扰类型:

$$\mathbf{Y} = (\mathbb{I}_1 \mathbb{I}_2 \cdots \mathbb{I}_K) \quad (19)$$

其中, \mathbb{I}_i 为示性函数, 表示信号中是否包含第*i*种干扰类型: 如果信号中包含该干扰类型, 则对应位置的标记为1, 否则为0。

表2 3个数据集的参数配置

Tab. 2 Parameter configurations for three datasets

数据集	参数	取值范围
1	总样本数	30000
	雷达带宽	10 MHz
	雷达脉宽	20 μ s
	雷达波长	0.1911 m
	干扰幅度	0.8~1.2
	SNR	-8~20 dB
	采样占空比	0.160~0.875
	速度	300~1200 m/s
	距离	1500~4900 m
	转发次数	2~6 次
1	噪声长度(SNISRJ-1)	0.5~1.5 μ s
	噪声长度(SNISRJ-2)	10~30 μ s
2	总样本数	40000
	SNR	0~20 dB
	速度	100~600 m/s
	距离	1500~5000 m
	干扰幅度	0.8~1.2
	采样占空比(ISRJ)	0.3~0.5
	谱线数(COMB)	5~15
	频率步长(COMB)	0.5~2.0 MHz
	切片数(SMSP)	2~4
	频率步长(SMSP)	1~3 MHz
2	采样宽度(C&I)	0.5~1.5 μ s
	采样周期(C&I)	1~6 μ s
	采样占空比(ISRJ)	0.1~0.5
	谱线数(COMB)	5~20
	切片数(SMSP)	2~8
	采样宽度(C&I)	0.8~1.8 μ s
3	采样周期(C&I)	1.6~7.2 μ s

具体的数据集标签分布信息如图5(a)和图5(c)所示。饼状图外围数字表示对应多标签二进制编码所映射的十进制编号，用于直观展示不同复合干扰类型的样本占比情况。相应的标签共现矩阵如图5(b)和图5(d)所示，该矩阵用于统计不同干扰标签在多标签样本中同时出现的相关程度，其中主对角线元素为1，其余非对角元素均趋近于0，表明不同干扰类别标签之间不存在统计相关性和共现依赖关系，从而保证了多标签学习过程中各干扰类型在统计意义上的相对独立性。通过这种标注方式，标注向量 \mathbf{Y} 可以反映信号中同时存在多种干扰源的情况，适用于多干扰源并存的复杂场景，多标签标注策略不仅能够处理单一干扰类型，还能准确反映复合干扰的共存关系，相比单标签标注的方法，多标签标注模型分类器类别少，参量低，训练时间短，

允许模型学习到不同干扰类型之间的相互关系及其对信号的影响。

4.1 实验环境与评价指标

本文所用的实验环境包括：RTX2080 Ti *2 GPU，显存为 22 GB；软件环境为PyTorch 2.5.1, Python 3.12及CUDA 12.4。在MATLAB 2024b环境中完成干扰数据的仿真，并将数据集划分为80%的训练集、10%的验证集和10%的测试集。数据集使用随机种子划分，避免数据泄露。模型训练过程中，最大迭代次数设为100个epoch，批量处理大小为256，选用Adam优化器，分类阈值设定为0.5，网络同时执行多标签分类与去噪任务，整体损失函数由二元交叉熵损失和最小均方误差损失共同构成，其中最小均方误差损失的权重设置为0.5：

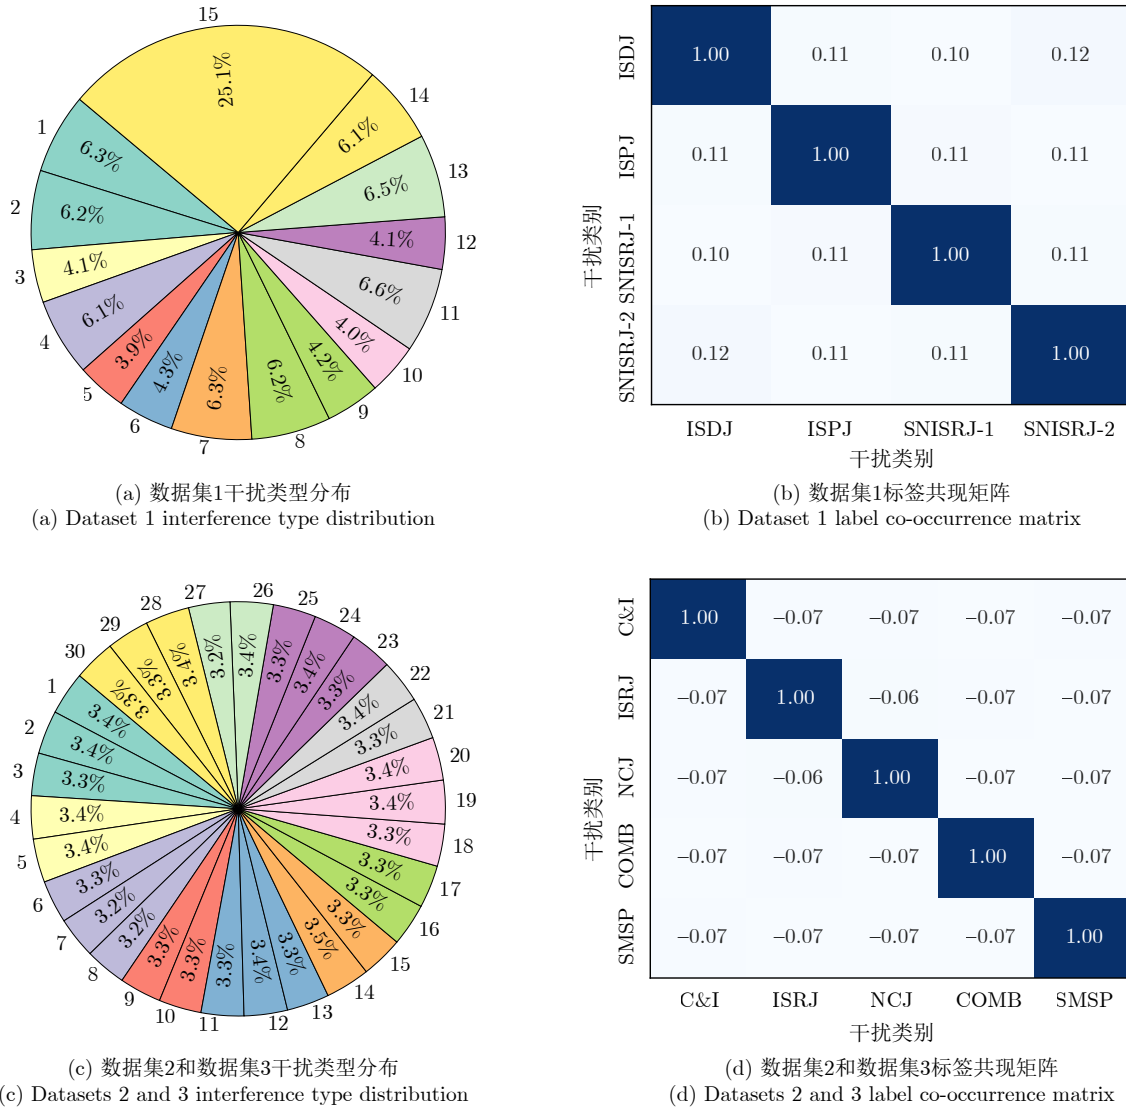


图 5 数据集分布情况

Fig. 5 Dataset distribution

$$\mathcal{L} = -\frac{1}{N_{\text{num}}} \sum_{i=1}^{N_{\text{num}}} \left[\mathbf{Y}_i \log(\hat{\mathbf{Y}}_i) + (1 - \mathbf{Y}_i) \log(1 - \hat{\mathbf{Y}}_i) \right] + 0.5 \frac{1}{N_{\text{num}}} \sum_{i=1}^{N_{\text{num}}} \left\| \mathbf{X}_i - \hat{\mathbf{X}}_i \right\|^2 \quad (20)$$

其中, N_{num} 表示训练样本的数量, \mathbf{Y}_i 表示第*i*个样本的真实多标签标注, $\hat{\mathbf{Y}}_i$ 表示网络对第*i*个样本输出的预测标签概率, \mathbf{X}_i 表示第*i*个样本对应的原始信号, $\hat{\mathbf{X}}_i$ 表示网络输出的去噪信号。

为全面评估模型性能, 本文采用子集准确率、准确率、精确度、召回率和F1分数等评估指标。其中, 子集准确率是严格的多标签分类评价指标, 要求模型对样本所有标签预测正确才视为正确分类:

$$\text{ACC} = \frac{1}{N_{\text{num}}} \sum_{i=1}^{N_{\text{num}}} \mathbb{I}(\mathbf{Y}_i = \hat{\mathbf{Y}}_i) \quad (21)$$

仅当预测标签集与真实标签集完全一致时取值为1, 否则为0。该指标对模型整体性能要求较高, 特别适用于评估复杂干扰环境下的识别能力。

准确率、精确度、召回率与F1分数是分类模型评价的经典指标: 准确率反映整体分类正确率; 精确度衡量模型预测正类的可靠性; 召回率反映模型避免漏报能力; F1分数综合表征模型的稳健分类性能。针对多标签分类场景, 我们采用宏平均方法计算指标并取均值, 以评估不同干扰类型的识别性能分析。此外, 本文还采用混淆矩阵对模型的干扰识别性能进行可视化分析。混淆矩阵对角线元素代表分类准确性, 非对角线元素代表类别间的误判模式, 为模型性能评估提供依据。

4.2 网络识别性能分析

为全面评估本文提出的基于先验引导与噪声抑制的雷达复合干扰识别网络的性能, 本节选取了近年来的代表性方法进行了对比实验, 包括多标签卷积神经网络(MLCNN)^[18]、基于时频图多标签分类网络(MLACM)^[18]、多特征融合雷达干扰辨识网络(FRFTNet)^[17]、轻量化混合注意力识别网络(ShuffleNetV2-EHA)^[20]、跨模态学习识别网络(CrossModality)^[32]、以及通用计算机视觉目标分类模型(YOLOv11)^[33], 为确保实验公平性, 所有基准模型均在统一场景下进行了训练, 二维时频图依赖模型采用了相同大小的时频图进行学习。

如表3所示, 本节首先使用数据集1详细对比了所提方法与现有辨识模型在信噪比为-8~20 dB范围内的各类ISRJ干扰的识别性能。评估指标涵盖精确率、召回率、F1分数以及子集准确率。实验结果表明, 由于本文网络充分引入了干扰信号的先

验引导机制, 并设计了针对性的噪声抑制策略, 其在各项性能指标上均显著优于各模型。在测试集上, 本文方法的平均子集准确率达到90%, 超过现有模型4%左右; 平均精确率, 平均准确率, 平均F1分数也超过现有模型4%左右。相比之下, 对比方法对复杂复合干扰的识别表现出不同程度的局限性: 通用视觉分类模型YOLOv11在面对多种干扰模式同时存在、信号相互叠加且特征边界模糊的复杂电磁对抗场景下识别性能较为有限; FRFT-Net采用单标签分类策略, 将不同干扰组合视为相互独立的类别进行建模, 未能有效提取不同干扰成分之间的有效和层级特征, 因此在复合干扰场景下的辨识度不佳。ShuffleNetV2-EHA与CrossModality虽然通过混合注意力机制或双流特征融合增强了特征提取能力, 子集准确率提升至86%左右, 但由于缺乏干扰信号的噪声抑制设计, 在低信噪比环境下的鲁棒性和泛化能力仍有不足。此外, CrossModality采用的ResNet骨干架构带来了较大的计算开销。

为进一步全面评估所提方法的泛化能力, 本节在噪声鲁棒方面对各模型进行了评估, 在-8~15 dB的6个SNR水平下进行了噪声泛化测试, 结果如图6所示。随着信噪比提升, 所有模型的性能均稳步改善, 但本文方法在全信噪比范围内始终保持领先。当SNR≥5 dB时, 本方法的子集准确率稳定在95%以上, 证明了本文的先验引导机制能有效缓解低信噪比条件下模型对噪声成分的过拟合。

同时, 在图7所示的混淆矩阵对比中, 本文将各干扰类型对应的多标签二进制映射为十进制类别进行分析。从混淆矩阵可以看出, 本文所提出方法的主对角线区域色块最为集中且颜色最深, 非对角元素较少且颜色较浅, 表明其误判率低、整体识别性能最优。

进一步地, 为验证网络对干扰类型的泛化能力, 采用数据集2构建包含C&I, ISRJ, NCJ, COMB及SMSP在内的5类干扰成分, 并通过组合形成30种复合干扰类型的复杂实验场景进行测试。图8展示了参数匹配和失配情况下各对比网络对不同干扰的识别准确率, 外围小圆圈是否染色代表该干扰类型是否存在, 雷达图及对应统计结果表4证明, 本文方法在30类复合干扰组合上的平均识别准确率始终保持最优, 达到90.66%。此外, 我们还采用数据集3对干扰参数失配条件下的识别性能进行评估, 当测试集中干扰参数偏离训练集分布时, 各对比模型的识别性能均出现不同程度的下降, 而本文方法的性能衰减最小, 整体识别效果最优, 证明

表 3 各类间歇采样转发干扰在不同网络模型下的识别性能对比

Tab. 3 Recognition performance comparison of various ISRJ types across different network models

评估类别	干扰类型	模型						
		YOLOv11	FRFTNet	MLACM	MLCNN	SNV2-EHA	CMNet	Proposed
单类干扰识别率(%)	1	90.55	99.50	98.59	99.85	99.90	98.39	99.90
	2	64.95	94.57	95.54	98.15	99.51	98.48	98.21
	3	75.54	91.24	90.62	99.49	96.78	95.54	99.38
	4	84.43	95.14	96.43	95.33	97.62	96.95	98.38
复合干扰识别率(%)	1+2	37.08	82.83	90.33	94.17	96.58	92.50	96.00
	2+4	19.61	49.22	68.83	63.88	78.64	82.04	78.93
	2+3	40.00	68.81	49.25	66.87	81.64	81.27	84.18
	2+3+4	20.15	41.24	34.95	57.68	70.93	71.29	78.66
	1+4	25.26	63.42	56.49	69.39	87.63	80.00	90.96
	1+3	42.41	76.98	63.97	87.16	89.74	90.43	89.22
	1+3+4	12.72	19.47	10.44	52.18	54.95	67.91	69.51
	3+4	34.22	65.62	27.50	68.36	76.56	72.03	83.20
	1+2+4	2.99	30.10	53.97	64.61	74.22	74.07	81.18
	1+2+3	34.26	47.35	78.70	85.37	80.62	84.20	87.78
总体效果(%)	1+2+3+4	89.67	89.20	92.30	91.32	93.28	92.83	97.13
	平均精确率	48.30	65.42	72.38	78.32	81.07	81.37	85.52
	平均召回率	42.12	63.42	63.00	74.61	79.91	79.87	83.29
	平均F1分数	42.78	63.38	63.55	75.98	80.27	80.47	84.24
模型复杂度	子集准确率	54.98	71.58	72.41	82.17	86.60	86.78	90.54
	浮点运算次(10^9)	0.183	0.166	0.652	0.005	0.037	4.596	0.160
	参数量(10^6)	1.20	0.66	33.78	0.04	0.65	92.66	0.16
	测试时间(s)	0.78	1.14	0.90	0.61	0.64	3.81	0.74

注：加粗表示最优指标；干扰1—4分别对应ISDJ, ISPJ, SNISRJ-1, SNISRJ-2；为方便布局，表格对模型名称进行了简化。

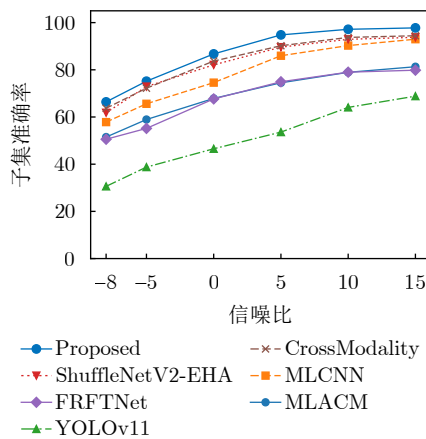


图 6 各模型噪声鲁棒性能图

Fig. 6 Evaluation of noise robustness for different models

本文所提出的先验引导机制能够基于干扰信号的对称性先验，自适应调节正负向特征权重，使模型在干扰类型增加及参数分布变化的场景下，表现出优异的鲁棒性。

在网络复杂度方面，由于本文方法直接基于一

维干扰时域信号及其小波分解特征进行建模，避免了二维时频变换所引入的大量冗余计算，卷积算子的计算复杂度相较于二维时频方案有所降低，从而有效控制了模型规模。得益于上述设计，所构建模型在识别性能最优的同时，其参数量仅为 1.6×10^5 ，浮点运算次数为 1.6×10^8 。与基于时频图并采用较复杂ResNet网络结构的方法相比，本文方法在参数规模和计算开销方面均实现了降低；同时，相较于实时目标检测网络YOLOv11以及同样基于一维干扰时域信号的MLCNN，本文模型的参数量未明显增长，满足了实际应用中轻量化与快速训练的需求。

4.3 模块有效性分析

图9展示了网络各阶段处理含噪复合干扰信号的优化效果，图9(c)灰色波形为原始加噪干扰信号，可以看出，干扰信号中的噪声得到显著抑制，在不含干扰信号的区段，噪声几乎被完全消除；在含干扰区段，模块通过先验保护分支在去噪的基础

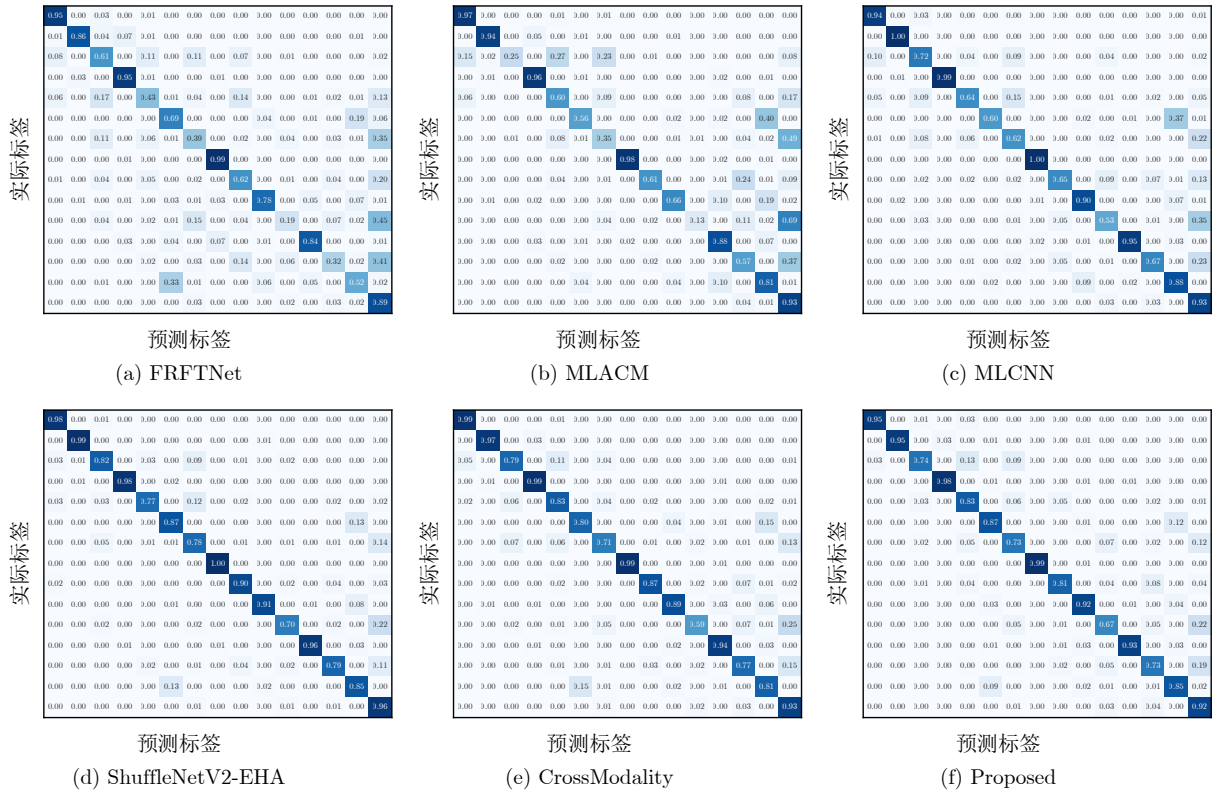


图7 本文与对比网络混淆矩阵结果图

Fig. 7 Confusion matrices of our method and comparative networks

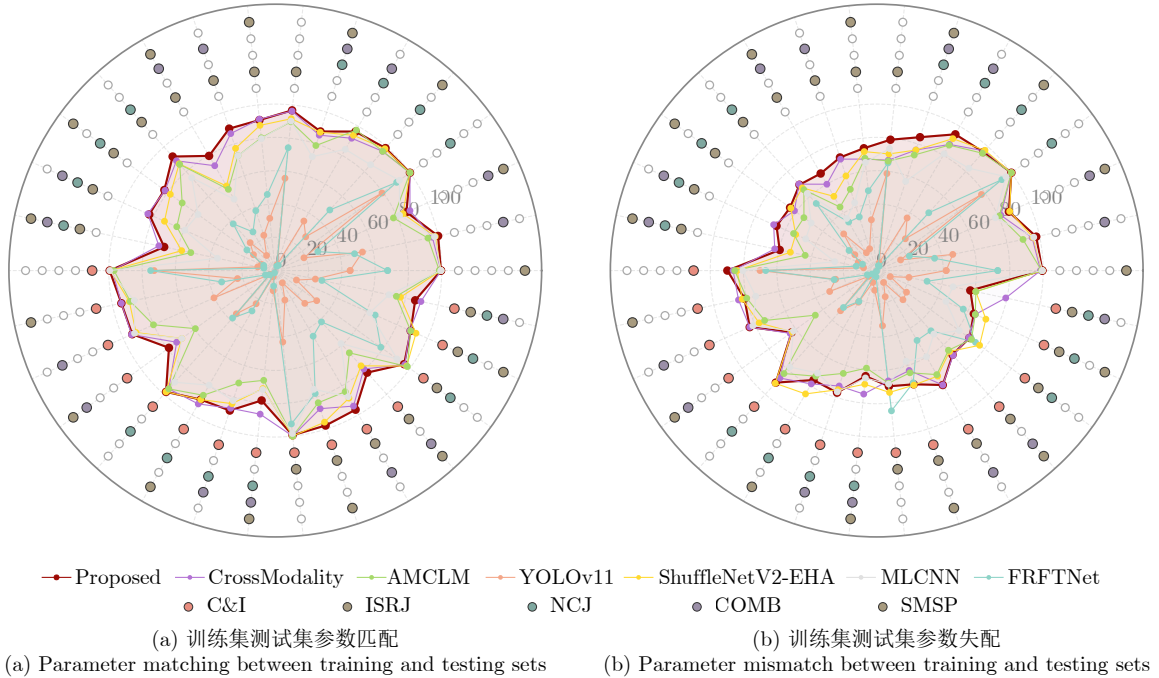


图8 复杂干扰数据集识别准确率雷达图

Fig. 8 Complex interference dataset classification accuracy radar chart

上保护了干扰的包络走势, 经过三阶段去噪, 信号质量得到了极大的提升, 定量评估表明, 原始加噪信号的平均结构相似性(Structural Similarity Index Measure, SSIM)均值为 0.3234, 皮尔逊(Pearson)

相关系数均值为0.7330, 在经过粗去噪模块处理后SSIM提升至0.4062, Pearson系数提升至0.8254, 在经过特征保护模块处理后SSIM提升至0.5000, Pearson系数提升至0.8685, 最终去噪信号处理后

表 4 不同模型在数据集2与数据集3上的性能对比
Tab. 4 Performance comparison on dataset 2 and dataset 3

序号	模型	数据集2准确率(%)	数据集3(失配)准确率(%)
1	Proposed	90.66	77.14
2	CrossModality	89.60	76.12
3	ShuffleNetV2-EHA	86.40	75.29
4	MLACM	81.79	70.06
5	MLCNN	78.21	65.68
6	FRFTNet	39.12	37.50
7	YOLOv11	27.36	25.63

注：加粗表示最优指标。

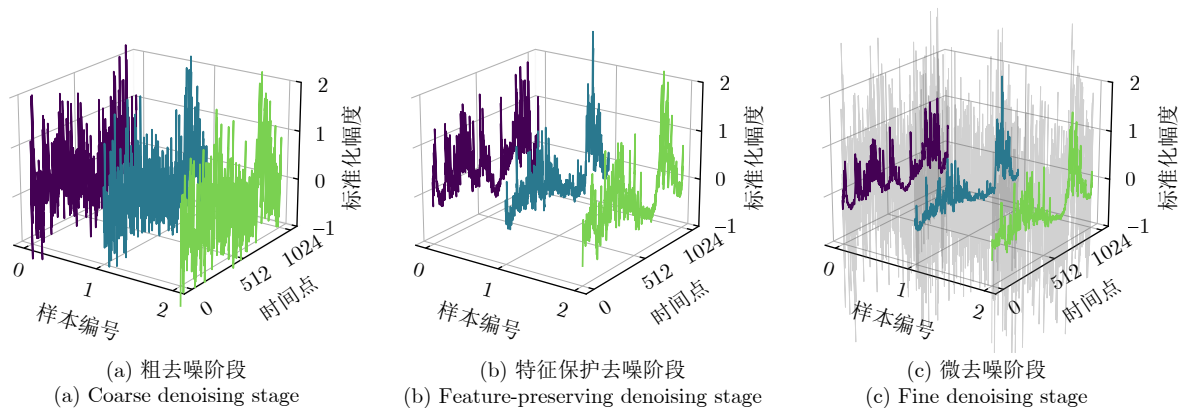


图 9 噪声抑制与特征优化效果图

Fig. 9 Visualization of noise suppression and feature optimization effects

SSIM提升至0.5976，Pearson系数提升至 0.8895，信号质量得到显著改善。因此，本文提出的模块在噪声抑制与特征增强两个层面有效提升了输入信号质量。优化后的信号为后续编码与时序建模环节提供了更高质量的特征向量，为后续对称编码器的特征提取提供了更清晰、稳定的输入，避免后续网络过拟合噪声特征。

同时，为验证各模块作用，本节通过逐一消融子模块并评估性能变化，定量衡量各模块对网络的贡献。结果如表5所示。对比实验1与实验2，在移除噪声抑制与特征优化模块后，模型总体准确率下降至87.21%，表明该模块在抑制背景噪声、保留关键信号成分以及增强信号结构先验方面发挥了重要作用。对比实验1与实验3，当分类器中去除噪声感知特征分量时，模型准确率降低至86.71%，说明噪声估计结果为分类过程提供了有效的噪声强度信息，去噪后噪声强度信息会缺失。对比实验1与实验4，在移除先验引导分支所提取的特征后，模型准确率显著下降至85.68%，下降最明显，表明先验引导机制能够有效增强对称性特征的表达能力，提升整体特征可分性。对比实验1与实验5，当去除小波分解细节系数特征时，模型准确率下降至

表 5 模块消融结果
Tab. 5 Ablation results of modules

实验	噪声抑制	噪声感知	先验引导	小波分支	准确率(%)
1	✓	✓	✓	✓	90.62
2		✓	✓	✓	87.21
3	✓		✓	✓	86.71
4	✓	✓		✓	85.68
5	✓	✓	✓		86.44
6		✓		✓	85.37
7			✓	✓	86.68
8		✓		✓	85.87
9				✓	84.43

注：加粗表示最优指标。

86.44%，说明小波分解所提供的多尺度细节纹理信息能够进一步丰富特征表达，从而有效提升模型对不同干扰类型的判别能力。最后，对比实验1与实验6至实验9，当多个网络模块被两两组合移除或全部移除时，模型性能均出现不同程度的退化，进一步验证了各功能模块在整体网络结构中的有效性与必要性。

5 结语

针对现有雷达复合干扰辨识方法中干扰先验信息利用不足、模型可解释性有限,以及缺乏有效噪声抑制机制、易产生噪声过拟合的问题,本文提出了一种干扰先验引导的轻量化噪声鲁棒雷达复合干扰多标签识别网络。该方法充分利用不同雷达干扰信号在时域上的时序先验特性,并结合小波分解提取的多尺度细节纹理信息,增强了复合干扰的特征表达能力,提升了整体识别性能。噪声抑制与特征优化模块采用三阶段去噪策略,有效抑制噪声并强化干扰信号的先验结构特征;特征编码与时序建模模块通过先验引导的对称编码器实现干扰正反向特征的门控融合;噪声感知分类模块将信噪比强度信息与信号特征进行联合建模,提升了模型在不同信噪比条件下的分类泛化能力。实验结果表明,在低信噪比条件下,所提出方法对15类ISRJ复合干扰及由ISRJ, SMSP, NCJ, C&I和COMB组成的30类复杂复合干扰的识别性能优于对比模型,且保持较低参数量,为雷达抗干扰波形设计提供了有效的辨识基础。未来研究将进一步拓展至干扰与目标信号共存的场景,实现复合干扰条件下对目标与干扰的联合辨识。

利益冲突 所有作者均声明不存在利益冲突

Conflict of Interests The authors declare that there is no conflict of interests

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. doi: [10.12000/JR22191](https://doi.org/10.12000/JR22191).
- [2] 刘振, 隋金坪, 魏玺章, 等. 雷达有源干扰识别技术研究现状与发展趋势[J]. 信号处理, 2017, 33(12): 1593–1601. doi: [10.16798/j.issn.1003-0530.2017.12.010](https://doi.org/10.16798/j.issn.1003-0530.2017.12.010).
- [3] 周胜文, 沙明辉, 胡小春. 基于梳状谱调制和间歇采样重复转发的复合干扰[J]. 系统工程与电子技术, 2021, 43(12): 3495–3501. doi: [10.12305/j.issn.1001-506X.2021.12.10](https://doi.org/10.12305/j.issn.1001-506X.2021.12.10).
- [4] JIE Xiao, WEI Xizhang, and SUN Jia. Interrupted-sampling multi-strategy forwarding jamming with amplitude constraints based on simultaneous transmission and reception technology[J]. *Digital Signal Processing*, 2024, 147: 104416. doi: [10.1016/j.dsp.2024.104416](https://doi.org/10.1016/j.dsp.2024.104416).
- [5] 周阳, 毕大平, 沈爱国, 等. 基于运动调制的SAR-GMTI间歇采样遮蔽干扰方法[J]. 雷达学报, 2017, 6(4): 359–367. doi: [10.12000/JR16075](https://doi.org/10.12000/JR16075).
- [6] 郭文杰, 吴振华, 曹宜策, 等. 多域浅层特征引导下雷达有源干扰多模态对比识别方法[J]. 雷达学报(中英文), 2024, 13(5): 1004–1018. doi: [10.12000/JR24129](https://doi.org/10.12000/JR24129).
- [7] WANG Zan, GUO Zhengwei, SHU Gaofeng, et al. Radar jamming recognition: Models, methods, and prospects[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2025, 18: 3315–3343. doi: [10.1109/JSTARS.2024.3522951](https://doi.org/10.1109/JSTARS.2024.3522951).
- [8] 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. doi: [10.16337/j.1004-9037.2022.01.001](https://doi.org/10.16337/j.1004-9037.2022.01.001).
- [9] HAO Guocheng, BU Laite, LU Mengyuan, et al. Radar jamming signal recognition algorithm based on multi-feature fusion[J]. *Digital Signal Processing*, 2025, 158: 104950. doi: [10.1016/j.dsp.2024.104950](https://doi.org/10.1016/j.dsp.2024.104950).
- [10] SHI Yuxin, LU Xinjin, NIU Yingtao, et al. Efficient jamming identification in wireless communication: Using small sample data driven naive Bayes classifier[J]. *IEEE Wireless Communications Letters*, 2021, 10(7): 1375–1379. doi: [10.1109/LWC.2021.3064843](https://doi.org/10.1109/LWC.2021.3064843).
- [11] 刘一兵, 罗强, 胡然, 等. 基于多维小波特征的有源雷达欺骗干扰识别[J]. 现代防御技术, 2024, 52(3): 120–127. doi: [10.3969/j.issn.1009-086x.2024.03.015](https://doi.org/10.3969/j.issn.1009-086x.2024.03.015).
- ZHOU Shengwen, SHA Minghui, and HU Xiaochun. Composite jamming based on comb spectrum modulation and interrupted sampling repetitive repeater[J]. *Systems Engineering and Electronics*, 2021, 43(12): 3495–3501. doi: [10.12305/j.issn.1001-506X.2021.12.10](https://doi.org/10.12305/j.issn.1001-506X.2021.12.10).
- ZHOU Yang, BI Daping, SHEN Aiguo, et al. Intermittent sampling repeater shading jamming method based on motion modulation for SAR-GMTI[J]. *Journal of Radars*, 2017, 6(4): 359–367. doi: [10.12000/JR16075](https://doi.org/10.12000/JR16075).
- GUO Wenjie, WU Zhenhua, CAO Yice, et al. Multidomain characteristic-guided multimodal contrastive recognition method for active radar jamming[J]. *Journal of Radars*, 2024, 13(5): 1004–1018. doi: [10.12000/JR24129](https://doi.org/10.12000/JR24129).
- LIU Yibing, LUO Qiang, HU Ran, et al. Active radar deception jamming recognition based on multi-dimensional wavelet features[J]. *Modern Defence Technology*, 2024, 52(3): 120–127. doi: [10.3969/j.issn.1009-086x.2024.03.015](https://doi.org/10.3969/j.issn.1009-086x.2024.03.015).

- [12] 王佳祥, 孟进, 李伟, 等. YOLO-S³: 一种轻量化的雷达复合干扰识别网络[J]. 雷达学报(中英文), 待出版. doi: [10.12000/JR25080](https://doi.org/10.12000/JR25080).
WANG Jiexiang, MENG Jin, LI Wei, *et al.* YOLO-S³: A lightweight network for radar composite jamming signal recognition[J]. *Journal of Radars*, in press. doi: [10.12000/JR25080](https://doi.org/10.12000/JR25080).
- [13] ZHAO Qingyuan, LIU Yang, CAI Linjie, *et al.* Research on electronic jamming identification based on CNN[C]. 2019 IEEE International Conference on Signal, Information and Data Processing, Chongqing, China, 2019: 1–5. doi: [10.1109/ICSIDP47821.2019.9172911](https://doi.org/10.1109/ICSIDP47821.2019.9172911).
- [14] LIN Junjie and FAN Xiaolei. Radar active jamming recognition based on recurrence plot and convolutional neural network[C]. 2021 IEEE 4th Advanced Information Management, Communicates, Electronic and Automation Control Conference, Chongqing, China, 2021: 1511–1515. doi: [10.1109/IMCEC51613.2021.9481990](https://doi.org/10.1109/IMCEC51613.2021.9481990).
- [15] WU Yaojun, DUAN Lining, YANG Liaoming, *et al.* Fine-grained recognition and suppression of ISRJ based on UNet-A[J]. *IEEE Geoscience and Remote Sensing Letters*, 2024, 21: 3508805. doi: [10.1109/LGRS.2024.3448611](https://doi.org/10.1109/LGRS.2024.3448611).
- [16] ZHOU Hongping, WANG Ziwei, WU Ruowu, *et al.* Jamming recognition algorithm based on variational mode decomposition[J]. *IEEE Sensors Journal*, 2023, 23(15): 17341–17349. doi: [10.1109/JSEN.2023.3283397](https://doi.org/10.1109/JSEN.2023.3283397).
- [17] ZHOU Hongping, WANG Lei, and GUO Zhongyi. Recognition of radar compound jamming based on convolutional neural network[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2023, 59(6): 7380–7394. doi: [10.1109/TAES.2023.3288080](https://doi.org/10.1109/TAES.2023.3288080).
- [18] ZHU Mengtao, LI Yunjie, PAN Zesi, *et al.* Automatic modulation recognition of compound signals using a deep multi-label classifier: A case study with radar jamming signals[J]. *Signal Processing*, 2020, 169: 107393. doi: [10.1016/j.sigpro.2019.107393](https://doi.org/10.1016/j.sigpro.2019.107393).
- [19] QU Qizhe, WEI Shunjun, LIU Shan, *et al.* JRNet: Jamming recognition networks for radar compound suppression jamming signals[J]. *IEEE Transactions on Vehicular Technology*, 2020, 69(12): 15035–15045. doi: [10.1109/TVT.2020.3032197](https://doi.org/10.1109/TVT.2020.3032197).
- [20] LV Qinzhe, FAN Hanxin, LIU Junliang, *et al.* Multilabel deep learning-based lightweight radar compound jamming recognition method[J]. *IEEE Transactions on Instrumentation and Measurement*, 2024, 73: 2521115. doi: [10.1109/TIM.2024.3400337](https://doi.org/10.1109/TIM.2024.3400337).
- [21] LIU Mei, GAO Xunzhang, QIU Xiangfeng, *et al.* Deep Gaussian hidden Markov network for robust HRRP sequence modeling and target recognition[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2025, 61(6): 19068–19083. doi: [10.1109/TAES.2025.3615896](https://doi.org/10.1109/TAES.2025.3615896).
- [22] LIU Mei, GAO Xunzhang, and ZHANG Zhiwei. Noise robust HRRP sequence recognition based on a deep unfolded go decomposition network[J]. *Signal Processing*, 2025, 230: 109876. doi: [10.1016/j.sigpro.2024.109876](https://doi.org/10.1016/j.sigpro.2024.109876).
- [23] ZHANG Lingyun, TAN Hui, and WANG Zhili. Interference response prediction of receiver based on wavelet transform and a temporal convolution network[J]. *Electronics*, 2024, 13(1): 162. doi: [10.3390/electronics13010162](https://doi.org/10.3390/electronics13010162).
- [24] YU Yifei, LI Yuanxiang, ZHOU Yunqing, *et al.* A learnable and explainable wavelet neural network for EEG artifacts detection and classification[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2024, 32: 3358–3368. doi: [10.1109/TNSRE.2024.3452315](https://doi.org/10.1109/TNSRE.2024.3452315).
- [25] 寇雯博, 董灏, 邹岷强, 等. 混杂复合材料等效热导性能预测的小波-机器学习混合方法[J]. 物理学报, 2021, 70(3): 030701. doi: [10.7498/aps.70.20201085](https://doi.org/10.7498/aps.70.20201085).
KOU Wenbo, DONG Hao, ZOU Minqiang, *et al.* Hybrid wavelet-based learning method of predicting effective thermal conductivities of hybrid composite materials[J]. *Acta Physica Sinica*, 2021, 70(3): 030701. doi: [10.7498/aps.70.20201085](https://doi.org/10.7498/aps.70.20201085).
- [26] SU Hanning, BAO Qinglong, PAN Jiameng, *et al.* Waveform-domain complementary signal sets for interrupted sampling repeater jamming suppression[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2024, 60(5): 7142–7158. doi: [10.1109/TAES.2024.3410952](https://doi.org/10.1109/TAES.2024.3410952).
- [27] 施富强, 周超, 刘泉华. 间歇采样重复转发式干扰特性分析[J]. 信号处理, 2017, 33(12): 1616–1624. doi: [10.16798/j.issn.1003-0530.2017.12.013](https://doi.org/10.16798/j.issn.1003-0530.2017.12.013).
SHI Fuqiang, ZHOU Chao, and LIU Quanhua. Characteristics analysis of interrupted-sampling repeater jamming[J]. *Journal of Signal Processing*, 2017, 33(12): 1616–1624. doi: [10.16798/j.issn.1003-0530.2017.12.013](https://doi.org/10.16798/j.issn.1003-0530.2017.12.013).
- [28] 潘小义, 刘晓斌, 陈吉源, 等. 间歇采样转发干扰技术研究述评[J]. 系统工程与电子技术, 2024, 46(9): 2887–2901. doi: [10.12305/j.issn.1001-506X.2024.09.01](https://doi.org/10.12305/j.issn.1001-506X.2024.09.01).
PAN Xiaoyi, LIU Xiaobin, CHEN Jiyuan, *et al.* Overview of intermittent sampling repeater jamming technology[J]. *Systems Engineering and Electronics*, 2024, 46(9): 2887–2901. doi: [10.12305/j.issn.1001-506X.2024.09.01](https://doi.org/10.12305/j.issn.1001-506X.2024.09.01).
- [29] WU Zhenhua, WANG Tengxin, CAO Yice, *et al.* Radar active deception jamming recognition based on Siamese squeeze wavelet attention network[J]. *IET Radar, Sonar & Navigation*, 2023, 17(12): 1886–1898. doi: [10.1049/rsn2.12482](https://doi.org/10.1049/rsn2.12482).
- [30] HUANG Junjie and DRAGOTTI P L. WINNet: Wavelet-inspired invertible network for image denoising[J]. *IEEE Transactions on Image Processing*, 2022, 31: 4377–4392. doi: [10.1109/TIP.2022.3184845](https://doi.org/10.1109/TIP.2022.3184845).

- [31] BATOOL I and IMRAN M. A dual residual dense network for image denoising[J]. *Engineering Applications of Artificial Intelligence*, 2025, 147: 110275. doi: [10.1016/j.engappai.2025.110275](https://doi.org/10.1016/j.engappai.2025.110275).
- [32] DONG Ganggang, WANG Zixuan, and LIU Hongwei. A cross-modality contrastive learning method for radar jamming recognition[J]. *IEEE Transactions on Instrumentation and Measurement*, 2025, 74: 2520811. doi: [10.1109/TIM.2025.3554858](https://doi.org/10.1109/TIM.2025.3554858).
- [33] WANG Yongyao, SUN Haiyang, LUO Kai, *et al.* A lightweight YOLOv11-based framework for small steel defect detection with a newly enhanced feature fusion module[J]. *Scientific Reports*, 2025, 15(1): 34322. doi: [10.1038/s41598-025-16619-9](https://doi.org/10.1038/s41598-025-16619-9).

作者简介

赵云飞, 硕士生, 主要研究方向为雷达信号处理。

刘梅, 博士生, 主要研究方向为智能感知与目标识别。

高勋章, 研究员, 主要研究方向为雷达目标特性与雷达目标识别。

刘烁炜, 副研究员, 主要研究方向为雷达目标识别。

(责任编辑: 于青)