



基于多模态特征融合的通信干扰识别方法

蒙童远, 胡邓华*, 石娟**, 孙际哲, 王振涛

(空军工程大学 防空反导学院, 陕西 西安 710051)

摘要: 针对复杂电磁环境下通信干扰信号类型识别准确率低、单一特征难以全面表征信号的问题,提出了一种基于多分支注意力机制融合网络(multi-branch attention fusion network, MBAF-Net)的干扰识别方法。该网络同时处理循环谱图、星座图、功率谱图和频域序列四种模态数据,针对不同模态特性选用不同网络提取深层特征;引入可学习加权机制自适应调整各模态贡献度,并通过自注意力模块对融合特征进行增强,充分挖掘特征维度间的内在依赖关系。实验结果表明,该方法在9类干扰信号识别任务中取得了优异的性能,在JNR ≥ -6 dB条件下识别准确率达到98%以上,识别性能优于传统方法。该网络方法充分融合了干扰信号的多域互补信息,具有较强的鲁棒性和泛化能力,为复杂电磁环境下通信干扰信号的精确识别提供了有效方法。

关键词: 通信干扰识别; 多模态特征融合; 卷积神经网络; 星座图; 通信抗干扰

中图分类号: TJ301 **文献标志码:** A **文章编号:** 1000-1093(XXXX)XX--10

Multimodal Feature Fusion-Based Method for Communication Interference Recognition

MENG Tongyuan, HU Denghua*, SHI Juan**, SUN Jizhe, WANG Zhentao

(Air Defense and Antimissile School, Air Force Engineering University, Xi'an, 710051, China)

Abstract: Addressing the challenges of low accuracy in identifying communication jamming signal types and the limitations of single features in comprehensively characterizing signals under complex electromagnetic conditions, this study proposes a multi-branch attention fusion network named MBAFNet. This network simultaneously processes four modalities of data: cyclic spectrum, constellation diagram, power spectrum, and frequency-domain sequence. It employs different networks to extract deep features tailored to the characteristics of each modality. A learnable weighting mechanism is introduced to adaptively adjust the contribution of each modality, while self-attention module enhances the fused features to fully exploit the inherent dependencies among feature dimensions. Experimental results demonstrate that the proposed method achieves recognition accuracy of over 98% at JNRs not less than -6 dB and significantly outperforming traditional approaches. By fully integrating multi-domain complementary information from interference signals, the network exhibits strong robustness and generalization capabilities, providing an effective solution for precise interference signal identification in complex electromagnetic environments.

Keywords: communication interference recognition; multimodal feature fusion; convolutional neural network; constellation diagram; communication anti-interference

收稿日期: 2026-04-03

基金项目: 青年科技英才项目(2024)

* 通信作者邮箱: 邮箱: hudenghua@qq.com; 邮箱: shijuan@mail.nwpu.edu.cn

DOI:10.12382/bgxb.2026.0301

0 引言

数字通信电台是支撑战场指挥、情报和控制等数据传输的重要设施。数字通信电台在战场上的工作环境日趋复杂,在遭受敌方强电磁干扰时,易发生通信中断、指挥链路失效等问题。通信系统通常采用跳频扩频方式提高通抗干扰能力,面对宽频谱阻塞式干扰,传统通信系统不能主动避让,仍然会在干扰频段间工作,出现‘盲跳频’现象^[1]。自适应跳频是在电台遭受恶意干扰后,自动识别干扰信号特征,主动避让干扰频段,使设备在不占用大量频率资源的前提下仍能正常工作的技术。识别干扰信号的类型,是进行干扰信号参数估计和规划自适应跳频策略的基础,因此,构建快速、精准的数字通信电台通信干扰识别体系,能够提升数字通信电台在复杂干扰环境下的适应能力与通信可靠性。

目前,国内外学者开展了通信干扰信号识别的大量研究,而基于深度学习的自动特征提取干扰信号识别网络是研究的重点方向^[2]。文献[3]将卷积神经网络应用于卫星通信链路干扰识别,实现了五类典型干扰信号的分类识别。文献[4]设计了基于改进的深度残差网络的干扰信号识别模型,在低干噪比(JNR)条件下实现已知和未知干扰的准确识别。文献[5]提出基于孪生神经网络的SNN-OWR新架构,将残差网络与变分自编码器相结合,动态检测未知干扰并实现无监督聚类。文献[6]设计了一种基于鲁棒功率谱特征的干扰识别网络,在低JNR下实现高精度识别。文献[7]提出DCRACNN框架,引入基于样本复杂度的自适应传播深度选择机制,极大提高模型推理速度。文献[8]提出了一种半监督小样本雷达干扰识别网络(SSJR-net),设计互学习策略并引入伪标签样本选择机制,在每类干扰仅1%的极端小样本标注数据下实现有效识别。文献[9]设计参数硬共享的多任务框架,采用改进多梯度下降算法联合优化并完成干扰识别和参数估计任务。文献[10]提出一种WPMNet的轻量化多尺度卷积神经网络,将输入IQ信号拆分为实部和虚部作为初始模态,实现端到端信号处理。同时,多域特征融合能够有效弥补单一域特征表征能力不足的缺陷^[11],已成为提升通信干扰识别性能的关键技术路径。文献[12]综合了时频域等多域特

征作为多模态输入,设计基于DenseNet的子网络结构和联邦学习的协同框架,在较小数据集上具有良好的识别性能。文献[13]提出了基于多模态异构小波分解神经网络的干扰样式识别模型,采用多模态特征提取框架,融合残差机制,双向长短期记忆网络(BiLSTM)与多尺度小波分解网络的三级级联架构实现深度特征挖掘。文献[14]设计DIINet框架,引入动态卷积技术,提取信号时频域、高阶统计等多维特征,实现网络参数自适应与轻量化。文献[15]将接收信号转化为包含人工特征、差分序列等多模态特征,设计模态信息选择机制(MISM)动态选择最优模态组合以节省计算开销。文献[16]设计一种多阶段Vision Transformer识别模型,提升分布式通信干扰信号的识别效率和精度。文献[17]提出一种基于YOLOv8的通信干扰信号识别网络,选取双谱变换、希尔伯特黄变换等多维异构特征,显著提升识别性能。文献[18]将干扰信号的时频图与时频序列作为双模态输入,利用Transformer架构动态提取融合局部和全局特征。该方法在JNR=-6 dB时,识别准确率可以达到92.2%。文献[19]提出一种轻量化双分支特征提取干扰信号识别网络,同时捕获时频域和分数傅里叶域特征,引入多域信息瓶颈理论降低特征冗余,特征提取参数量较先进轻量化模型降低91.7%。然而,现有多模态融合方法在干扰信号识别中面临三个共性问题:一是大多数方法采用时频域、IQ序列及其衍生的时频域峰度参数等特征模态,在实际工程中极易在低JNR条件下被噪声淹没,导致特征区分度骤降;二是各模态之间缺乏明确的物理互补性,特征之间的关联性难以用信号与干扰的物理原理进行解释,降低了其在军事装备应用中的可信度;三是当前基于模态选择^[15]或交叉注意力^[18]等特征融合策略,难以在保留完整有效模态信息、控制模型计算量及自适应调节不同模态可靠性之间实现较好的权衡。因此,针对低JNR场景下多模态特征协同表征和稳定融合的问题,仍有进一步研究的必要。

基于上述分析,本文提出了一种基于多分支注意力机制融合网络(Multi-branch Attention Fusion Network, MBAFNet)的通信干扰识别方法。该方法联合利用星座图、功率谱图、循环谱图及频域序列四类特征,从不同物理视角对干扰信号进行联合表征,并通过可学习加权融合与自注意力特征增强模块,实现多模态信息的有效协同建模。综上,本文主要工作包括:

1) 构建四模态联合表征框架,增强对复杂通信干扰信号的描述能力;

2) 设计可学习加权融合策略与自注意力特征增强模块,使模型能够自适应调节不同模态的贡献度,提升联合表征能力;

3) 通过对比实验和消融实验分析所提方法在不同条件下的识别性能,证明其在复杂场景下的有效性和稳定性。

1 信号接收系统

1.1 干扰信号库

有干扰的通信接收信号表示为

$$r(t) = Ks(t) + n_w(t) + j(t) \quad (1)$$

其中, K 为信道参数; $s(t)$ 为发射端信号; $n_w(t)$ 为加性高斯白噪声; $j(t)$ 为干扰信号。

通信干扰信号通常分为模拟干扰信号和数字干扰信号,本文仿真生成9类干扰信号作为干扰识别任务的样本库,样本能够覆盖战场环境主要电磁干扰信号。

(1)模拟干扰信号:单音干扰(single tone jamming, STJ)、多音干扰(multi-tone jamming, MTJ)、线性扫频干扰(linear frequency modulation, LFM)、噪声调频干扰(noise frequency modulation, NFM)、脉冲干扰(pulse noise jamming, PNJ)、梳状谱干扰(comb spectrum jamming, CSJ)。

(2)数字调制干扰信号:BPSK干扰、8FSK干扰、QAM16干扰。

1.2 干扰信号特征

数据质量是提升模型可信度的核心环节^[20],高辨识度的特征是实现高效分类识别的基础。利用深度学习网络的自动分类识别方法,对输入特征的可解释性有较高要求。针对时频图、IQ序列等特征易失真和稳定性不足的问题,本文尝试从调制域、循环结构、频谱能量分布及频域动态演化等四个角度构建更具互补性的联合表征。

1.2.1 星座图

通信信号经过解调后,分解为I支路信号和Q支路信号,用坐标 (a_n, b_n) 表示。

$$\begin{aligned} a_n &= s_1 + n_1 + j_1 \\ b_n &= s_2 + n_2 + j_2 \end{aligned} \quad (2)$$

式中, s_1, s_2 为M进制信号I支路和Q支路幅值,为理想星座点的坐标; n_1, n_2 是高斯随机变量; j_1, j_2 是干扰信号在I支路和Q支路上的分量。

图1展示了在JNR = 4 dB条件下,不同干扰信

号对QPSK信号星座图的影响。




图1 JNR = 4 dB时不同干扰下QPSK解调星座图

Fig. 1 QPSK demodulation constellation diagrams under various interference conditions at JNR = 4 dB

无干扰情况下,只有高斯噪声的星座点会在理想点附近呈现高斯分布,当存在干扰信号时,由于在信号上叠加了不同规律的向量,会导致星座点发生变化。星座图是大量信号点在复平面上的统计分布特性,对时间变化和噪声冲击不敏感,同时能直观反映通信系统的受干扰情况。由图1可以观察到,星座图畸变主要体现在以下几个维度:

(1)干扰导致星座点偏离理想位置,散布范围与干扰强度相关;

(2)理想星座簇为圆形或对称点,受干扰后可能变成椭圆、环状或不规则形状;

(3)干扰可能导致不同符号簇之间的区分度下降;

(4)不同区域的星座点密度发生变化。

单音、线性扫频和8FSK干扰均使星座图的符号簇呈环状分布,多音和噪声调频干扰均使符号簇扩散,说明仅通过单一星座图特征难以实现所有干扰信号识别。

1.2.2 循环谱图

谱相关密度是描述循环平稳信号在频率域和循环频率域联合特性的二维函数。谱相关密度函

数(spectral correlation density, SCD)的表达式为

$$S_x^\alpha[k] = \sum_{m=-M}^M R_x^\alpha[m] e^{-j2\pi km/M} \quad (3)$$

$R_x^\alpha[m]$ 为循环自相关函数(cyclic autocorrelation function, CAF),定义为:

$$R_x^\alpha[m] = \frac{1}{N} \sum_{n=0}^{N-1} x[n+m] x^*[n] e^{-j2\pi \alpha n/m} \quad (4)$$

其中, $x[n]$ 为输入信号; $x^*[n]$ 为复共轭; α 为循环频率; m 为时延变量; N 为样本总数。

本文截取序列长度为1024的信号进行加窗,计算谱相关密度并归一化后得到对应循环谱图。

1.2.3 功率谱图

功率谱密度(power spectral density, PSD)是描述信号功率在频域上的分布情况的特征,本文采用平均周期图法估计干扰信号的功率谱。

设每个干扰样本的复基带信号长度为 N ,将其分割为 K 个不重叠的短时窗,窗长 $L = 1024$ 。对每个窗内的数据施加汉宁窗以抑制频谱泄漏,通过快速傅里叶变换得到该窗的频谱 $X_k(f)$,进而得到该窗的周期图 $P_k(f) = |X_k(f)|^2$ 。最后将所有 K 个窗的周期图取平均,得到该样本的功率谱估计。

$$\hat{P}(f) = \frac{1}{K} \sum_{k=1}^K P_k(f) \quad (5)$$

为消除不同样本间因信号幅度差异带来的量纲影响,并便于后续神经网络训练,对估计得到的功率谱进行最大值归一化。

$$P_{\text{norm}}(f) = \frac{\hat{P}(f)}{\max \hat{P}(f)} \quad (6)$$

图2为JNR = 4 dB时不同干扰下信号功率谱特征图。

1.2.4 频域序列

对于离散时间信号 $x[n]$,其离散傅里叶变换(discrete fourier transform, DFT)定义为

$$X[k] = \sum_{n=0}^{N-1} x[n] e^{-j\frac{2\pi}{N} kn}, k = 0, 1, \dots, N-1 \quad (7)$$

其中, $X[k]$ 为第 k 个频率分量的复系数。本文采用快速傅里叶变换(fast fourier transform, FFT)高效实现上述变换。

2 MBAFNet干扰识别方法

针对传统单一网络特征提取不充分,处理多种类信号能力较弱的问题,本文提出一种基于多分支注意力机制融合网络(multi-branch attention fusion




图2 JNR = 4 dB时不同干扰下功率谱特征图

Fig. 2 Power spectrum characteristics under different interference conditions at JNR = 4 dB

network, MBAFNet)的干扰信号识别方法。该网络结构图如图3所示。该网络同时处理星座图、循环谱图、功率谱图以及频域序列特征四种模态数据,通过独立分支网络提取深层特征,再经特征融合与注意力机制联合优化,得到干扰类型。

2.1 特征提取模块

输入的I/Q信号序列首先经过星座域、循环时域、功率域及频域信息提取,针对不同模态信息特性选取合适的网络进行特征提取。

2.1.1 图像分支特征提取

星座图、循环谱图与功率谱图作为典型的信号图像特征,分别从调制域、循环频率域及功率域等不同维度对接收信号的本质特性进行刻画。

为了统一框架实现对星座图、循环谱图及功率谱图三种图像特征的深度提取与融合表示,本文将三类图像设置为尺寸为224×224的三通道RGB图像,采用结构相同但参数独立的ResNet18网络作为图像分支特征提取的骨干网络。考虑到循环谱图、星座图和功率谱图三类图像特征在分布与语义上存在较大差异,各图像分支采用独立训练的方式,互不共享参数,以充分挖掘各自模态的判别信息。网络的具体结构如表1所示。

2.1.2 频域序列分支特征提取

时序信号建模任务中,时域信号往往存在冗余度高、波动剧烈且噪声干扰分散的问题,导致传统建模方法难以高效捕捉信号的本质特征与长期依




图3 MBAFNet干扰信号识别网络结构图

Fig. 3 Architecture of the MBAFNet interference signal recognition network

表1 图像特征提取分支网络结构

Table 1 Branched network architecture for image feature extraction

层名称	操作类型	卷积核大小	步长	输入通道	输出通道	激活函数	归一化方式	输出尺寸
输入层	-	-	-	3(RGB)	-	-	-	224×224
Conv1	卷积+BN+ReLU	7×7	2	3	64	ReLU	BatchNorm	112×112
MaxPool	最大池化	3×3	2	64	64	-	-	56×56
Layer1	2个 BasicBlock	3×3	[1,1]	64	64	ReLU	BatchNorm	56×56
Layer2	2个 BasicBlock	3×3	[2,1]	64	128	ReLU	BatchNorm	28×28
Layer3	2个 BasicBlock	3×3	[2,1]	128	256	ReLU	BatchNorm	14×14
Layer4	2个 BasicBlock	3×3	[2,1]	256	512	ReLU	BatchNorm	7×7
Global AvgPool	自适应平均池化	-	-	512	512	-	-	1×1
FC	全连接	-	-	512	256	-	-	1×256

赖关系。相比之下,将时域信号转换为频域序列后,信号能量会集中在少数关键频点,呈现出更强的稀疏性与结构化特征,这一特性能够有效降低模型的学习难度,提升特征提取的效率。长短期记忆网络(LSTM)作为一种擅长捕捉时序序列长期依赖关系的模型,其循环结构天然适配频域序列的内在特性^[21]。

TF-LSTM作为频域序列分支的特征提取网络,

具体处理流程如下:首先将每个干扰样本划分为多个重叠的时间窗,窗长 $L = 1024$,窗口重叠率为0.5,时间窗数 $T = 8$ 。然后对每个时间窗内的信号序列施加汉明窗,并计算快速傅里叶变换,取其幅度谱,从而得到该样本的时频表示矩阵 $\mathbf{X} \in \mathbb{R}^{T \times L}$,其中 T 为时间窗数目, L 为FFT点数。

将时频矩阵 $\mathbf{X}$ 输入至 LSTM 分支。该分支采用两层堆叠的长短期记忆网络,隐藏层维度 $H = 128$,

并在层间引入Dropout正则化,丢弃概率 $p = 0.1$,以防止过拟合。LSTM的前向传播过程可表示为:

$$\begin{aligned} \mathbf{h}_t^{(1)} &= \text{LSTM}^{(1)}(\mathbf{x}_t, \mathbf{h}_{t-1}^{(1)}), \quad t = 1, 2, \dots, T \\ \mathbf{h}_t^{(2)} &= \text{LSTM}^{(2)}(\mathbf{h}_t^{(1)}, \mathbf{h}_{t-1}^{(2)}), \quad t = 1, 2, \dots, T \end{aligned} \quad (8)$$

其中 $\mathbf{h}_t^{(1)}$ 和 $\mathbf{h}_t^{(2)}$ 分别表示第一层和第二层在时刻 t 的隐藏状态。为聚合整个序列的信息,对第二层所有时刻的隐藏状态进行平均池化,得到固定长度的特征向量:

$$\mathbf{f}_{\text{lstm}} = \frac{1}{T} \sum_{t=1}^T \mathbf{h}_t^{(2)} \in \mathbb{R}^{128} \quad (9)$$

LSTM网络单元结构图如图4所示。




图4 LSTM网络单元

Fig. 4 LSTM network unit

2.2 特征融合模块

为充分整合四个分支提取的互补特征,本文设计了一个基于可学习加权拼接与自注意力增强的特征融合模块。该模块首先对四个分支的输出特征向量进行加权融合,随后在其后引入自注意力机制进一步捕获特征维度间的内在依赖关系,最终得到具有更强判别能力的联合表示。

假设四个分支的输出特征向量分别为: $\mathbf{f}_c \in \mathbb{R}^{256}$, $\mathbf{f}_h \in \mathbb{R}^{256}$, $\mathbf{f}_p \in \mathbb{R}^{256}$, $\mathbf{f}_l \in \mathbb{R}^{128}$, 分别对应星座图、循环谱图、功率谱图及频域特征分支。为自适应调整各模态对最终识别任务的贡献,引入一组可学习的融合权重 $\mathbf{w} = [w_c, w_h, w_p, w_l]$,初始化为均匀分布 $1/4$,在训练过程中通过反向传播优化。为避免权重值过大或过小,采用Softmax函数进行归一化。

$$\hat{w}_i = \frac{\exp(w_i)}{\sum_{j \in \{c, h, p, l\}} \exp(w_j)}, \quad i \in \{c, h, p, l\} \quad (10)$$

归一化后的权重与对应特征向量逐元素相乘,得到加权后的特征,最后将所有加权特征沿通道维度联合构成融合特征向量。

$$\mathbf{f}_{\text{fuse}} = [\tilde{\mathbf{f}}_c; \tilde{\mathbf{f}}_h; \tilde{\mathbf{f}}_p; \tilde{\mathbf{f}}_l] \in \mathbb{R}^{896} \quad (11)$$

与固定权重融合方式相比,可学习加权融合机制能够根据训练过程自适应调节不同模态对最终判决的贡献度。当某一模态在不同JNR条件下受到影响较大时,其对应权重可被相应抑制;而当某一模态具有更高判决价值时,其贡献可被进一步增强。进一步地,与离散模态选择机制不同,本文采用连续软性权重,不对任何模态进行硬性舍弃,从而在低JNR条件下保留了各模态可能存在的互补判别信息;同时本文所采用方法仅需学习4个可标量权重,参数量和计算开销均显著降低。

多通道联合构成的融合特征包含了多模态信息,但不同维度之间可能存在冗余或复杂的非线性关系。为增强特征的表达能力,在融合特征之后引入自注意力模块,该模块能够构建特征内部的依赖性,突出主要成分,抑制无关信息的影响。自注意力模块的结构如图5所示。




图5 自注意力模块

Fig. 5 Self-attention module

为充分挖掘融合特征向量 $\mathbf{F}_{\text{fused}} \in \mathbb{R}^{896}$ 中不同维度之间的内在依赖关系,本文将其重塑为序列形式 $\mathbf{S} \in \mathbb{R}^{896 \times 1}$

$$\mathbf{S} = \text{reshape}(\mathbf{F}_{\text{fused}}(896, 1)) \in \mathbb{R}^{896 \times 1} \quad (12)$$

将每个特征维度视为一个独立的 token, 序列长度 $L = 896$, 每个 token 的原始特征维度为 1。随后采用单头自注意力机制对这些 token 进行全局交互。

首先通过线性变换矩阵 $\mathbf{W}_Q, \mathbf{W}_K, \mathbf{W}_V \in \mathbb{R}^{112 \times 1}$ 将每个 token 映射到查询、键、值空间, 得到 $\mathbf{Q}, \mathbf{K}, \mathbf{V} \in \mathbb{R}^{896 \times 112}$ 。然后计算注意力权重矩阵。

$$\mathbf{A} = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{112}}\right)\mathbf{V} \in \mathbb{R}^{(896 \times 112)} \quad (13)$$

最后通过输出投影矩阵 $\mathbf{W}_O \in \mathbb{R}^{112 \times 1}$ 将每个 token 的表示映射回维度 1, 引入残差连接与层归一化, 得到增强后的特征 $\mathbf{f}_{\text{att}}$

$$\mathbf{f}_{\text{att}} = \text{LayerNorm}(\mathbf{f}_{\text{fuse}} + \mathbf{A}\mathbf{W}_O) \quad (14)$$

自注意力模块配置参数如表 2 所示。

表 2 自注意力模块配置参数

Table 2 Configuration parameters of self-attention module

参数名称	值
输入维度	896
隐藏维度	112
Query / Key / Value 输出维度	112
注意力头数	1
Dropout 比率	0.1
层归一化	896

2.3 全连接分类器

在获得自注意力增强后的融合特征向量后, 本文设计三层全连接网络作为分类器, 将特征映射至 9 种干扰类别。网络结构如表 3 所示。

表 3 全连接分类器网络结构

Table 3 Fully connected classifier network architecture

层序号	层类型	输入维度	输出维度	激活函数	Dropout
1	全连接层	896	512	ReLU	0.5
2	全连接层	512	256	ReLU	0.3
3	全连接层	256	9	线性	-

该分类器采用多层非线性变换, 在提升模型识别能力的同时, 通过 Dropout 机制控制复杂度, 增强泛化性能。

3 仿真分析

3.1 参数设置

本节搭建仿真通信系统链路模型, 采用 QPSK 调制方式和相干解调, 设置载波 $f_c = 10$ MHz, 符号率 $R_s = 2$ MHz, 采样频率 $f_s = 50$ MHz。通信系统通过 AWGN 信道, 设置信噪比 $\text{SNR} = 10$ dB。仿真生成九种典型模拟和数字调制干扰信号, 干扰信号参数在解调频率范围内服从均匀分布, 所有信号样本均为独立生成数据, 所有模态特征均由同一样本的原始信号计算得到, 不同样本之间没有时序或片段重叠关系。JNR 设置范围为 -20 dB~ 4 dB, 每隔 2 dB 取一个值, 每个 JNR 下采集 300 个样本, 每个样本采集 5000 个点。实验基于 NVIDIA RTX 5060 Laptop GPU 仿真平台。仿真设定 Batch size 为 64, 训练轮数为 100 轮, 设置早停轮数为 15 轮, 采用 Adam 优化器, 学习率设置为 0.001。将所有干扰信号样本随机打乱后按照 60%、20%、20% 的比例划分训练集、验证集、测试集。

3.2 结果分析

为了验证本文特征提取网络选用的合理性, 实验对比了包括 ResNet18、VGG16 及 GoogleNet 的 3 种深度学习网络对干扰信号特征的提取能力。图 6 展示了 5 次独立重复实验下各模型在不同 JNR 条件下的平均识别准确率。




图 6 不同特征提取网络下模型识别准确率曲线

Fig. 6 Model accuracy curves for different feature extraction networks

从整体趋势可以看出, 随着 JNR 提升, 三种网络的识别性能均呈上升趋势, 但 ResNet18 方案在中低 JNR 区间内表现更为稳定, 尤其在 -10 dB 至 -6

dB 区间具有较明显优势。具体实验数据详见表4。

表4 不同特征提取网络下模型识别准确率指标统计

Table 4 Recognition accuracy statistics of models with different feature extraction networks

JNR/ dB	GoogLeNet	VGG16	ResNet18
-20	20.73% ± 3.29%	15.52% ± 2.07%	14.72% ± 2.61%
-18	33.31% ± 2.76%	19.17% ± 2.51%	18.54% ± 2.48%
-16	40.96% ± 3.85%	23.13% ± 3.70%	25.30% ± 2.37%
-14	50.19% ± 2.49%	35.64% ± 3.29%	41.66% ± 5.98%
-12	59.44% ± 3.04%	55.27% ± 4.13%	61.84% ± 5.64%
-10	71.67% ± 2.82%	70.91% ± 3.94%	83.27% ± 4.27%
-8	77.62% ± 3.11%	81.70% ± 3.62%	94.96% ± 1.36%
-6	91.74% ± 1.09%	92.44% ± 1.73%	98.21% ± 0.29%
-4	96.58% ± 1.20%	98.87% ± 0.15%	99.52% ± 0.24%
-2	97.73% ± 0.24%	99.63% ± 0.11%	99.79% ± 0.12%
0	98.42% ± 0.26%	99.57% ± 0.19%	99.94% ± 0.03%
2	98.60% ± 0.18%	99.41% ± 0.20%	100% ± 0.00%
4	99.87% ± 0.11%	99.68% ± 0.07%	100% ± 0.00%

当 JNR 为 -10 dB 时,所提模型的识别准确率 达到 83%;当 JNR 提升至 -8 dB 时,识别准确率上 升至 94.9%;当 JNR 不低于 -6 dB 时,整体识别准 确率保持在 98% 左右。这表明在分辨区间内,本文 方法能够对多类通信干扰建立较稳定的判别边界。


从不同图像骨干网络的对比结果来看, ResNet18 由于残差结构在深层特征传播和训练稳 定性方面具有优势,更适合作为本文三类图像模态 的统一特征编码器;VGG16 虽然在较高 JNR 区间 能够保持较高精度,但在低 JNR 条件下对细粒度差 异的鲁棒性略弱;GoogLeNet 在部分区间也表现出 一定识别能力,但总体稳定性不及 ResNet18。

九种干扰信号识别在 JNR = -8 dB 和 JNR = 0 dB 时的混淆矩阵如图 7 所示。


由图 7(a)可以看出,在 JNR = -8dB 情况下, 8FSK 信号容易误判,导致整体识别率降低。表 5 展 示了 MBAFNet 网络的部分性能参数值。FLOP 为单 次推理计算复杂度。

3.3 消融实验

为了分析 MBAFNet 识别网络各模块对整体识 别过程的影响,实验仿真设置了 6 组消融对照实验。 每组实验只消除一个固定分支或模块,同时保证训 练样本、训练参数的一致性,使用固定随机种子确



(a) JNR = -8 dB



(b) JNR = 0 dB

图7 MBAFNet识别网络在不同JNR下的混淆矩阵
Fig. 7 Confusion matrix for MBAFNet recognition network at different JNR

表5 MBAFNet网络性能参数
Table 5 MBAFNet network performance parameters

参数名称	值
参数量	35.6M
FLOPs	10.8G
推理时间	12.572ms
显存占用	799.37MB

保样本划分相同。图8为各消融实验组识别准确率曲线图。




图8 各消融实验组识别准确率曲线图

Fig. 8 Accuracy curves for each ablation experiment group

实验结果表明,各分支和模块均对整体识别性能具有积极作用,但贡献程度存在明显差异。以 $JNR = -4$ dB 为例,完整模型的识别准确率为 99.5%;移除融合后特征增强模块后,识别准确率下降至 97.4%;移除可学习加权融合模块更换为平均

加权后,识别准确率下降至 85.1%;移除星座图分支后,识别准确率显著下降至 47.8%;移除频域序列分支后,识别准确率下降至 89.3%;移除循环谱图分支和功率谱图分支后,识别准确率分别下降至 97.5% 和 98.4%。上述结果表明,四类模态均能够为最终识别提供有效补充,其中星座图分支、频域序列分支及可学习加权融合模块对整体性能提升的作用更为显著。

进一步分析可知,星座图分支之所以贡献较大,主要在于其能够较稳定地保留干扰对调制状态造成的整体影响,在低 JNR 条件下仍具有较好的结构可分性;频域序列分支的重要性则体现在其能够刻画信号频谱在不同时间窗下的动态变化,为静态二维图像模态补充时序判别信息。相比之下,循环谱图和功率谱图虽然在大多数条件下同样能够提供有效判别依据,但在极低 JNR 条件下更容易受到随机噪声影响,其单独贡献略低于前两者。上述结果从侧面说明,本文所选取的四类模态在功能上具有明确分工,能够从不同角度共同支撑低 JNR 条件下的通信干扰识别。各消融实验组结果的具体数值详见表6。

表6 各消融组在不同JNR下的识别准确率数值

Table 6 Recognition accuracy of each ablation group at different JNR

JNR/ dB	消除 self- attention	消除 Learnable Weight Fusion	消除频域序列分 支	消除功率谱图分 支	消除循环谱图分 支	消除星座图分支	MBAFNet
-20	12.31% $\pm$ 3.89%	13.92% $\pm$ 3.31%	15.42% $\pm$ 2.56%	16.46% $\pm$ 2.79%	11.84% $\pm$ 2.34%	12.23% $\pm$ 1.04%	14.72% $\pm$ 2.61%
-18	19.15% $\pm$ 2.17%	18.45% $\pm$ 2.70%	16.47% $\pm$ 3.54%	19.18% $\pm$ 2.94%	13.23% $\pm$ 2.42%	12.36% $\pm$ 1.38%	18.54% $\pm$ 2.48%
-16	25.61% $\pm$ 3.96%	25.32% $\pm$ 3.64%	20.72% $\pm$ 4.12%	25.56% $\pm$ 3.07%	16.69% $\pm$ 2.98%	12.51% $\pm$ 1.43%	25.30% $\pm$ 2.37%
-14	36.64% $\pm$ 2.10%	44.41% $\pm$ 4.13%	29.77% $\pm$ 5.31%	40.27% $\pm$ 4.69%	28.74% $\pm$ 4.68%	14.32% $\pm$ 1.32%	41.66% $\pm$ 5.98%
-12	50.92% $\pm$ 5.36%	59.76% $\pm$ 3.78%	43.64% $\pm$ 4.69%	59.84% $\pm$ 4.62%	55.31% $\pm$ 5.59%	18.87% $\pm$ 1.83%	61.84% $\pm$ 5.64%
-10	70.12% $\pm$ 3.22%	64.51% $\pm$ 2.32%	58.28% $\pm$ 4.58%	70.36% $\pm$ 3.71%	68.10% $\pm$ 4.92%	28.90% $\pm$ 2.56%	83.27% $\pm$ 4.27%
-8	83.79% $\pm$ 1.04%	70.38% $\pm$ 1.82%	66.13% $\pm$ 2.59%	82.86% $\pm$ 1.59%	80.24% $\pm$ 3.77%	36.14% $\pm$ 4.81%	94.96% $\pm$ 1.36%
-6	94.75% $\pm$ 1.06%	81.46% $\pm$ 1.66%	78.54% $\pm$ 2.72%	94.81% $\pm$ 0.86%	91.93% $\pm$ 1.84%	42.11% $\pm$ 3.76%	98.21% $\pm$ 0.59%
-4	97.47% $\pm$ 0.82%	85.10% $\pm$ 1.46%	89.38% $\pm$ 1.87%	98.48% $\pm$ 0.14%	97.57% $\pm$ 0.93%	47.86% $\pm$ 4.21%	99.52% $\pm$ 0.24%
-2	98.44% $\pm$ 0.31%	89.37% $\pm$ 1.58%	96.61% $\pm$ 1.91%	99.52% $\pm$ 0.17%	99.50% $\pm$ 0.32%	58.32% $\pm$ 3.89%	99.79% $\pm$ 0.12%
0	99.59% $\pm$ 0.28%	91.24% $\pm$ 1.37%	97.54% $\pm$ 1.59%	99.86% $\pm$ 0.16%	99.81% $\pm$ 0.17%	66.96% $\pm$ 4.52%	99.94% $\pm$ 0.03%
2	99.87% $\pm$ 0.13%	94.69% $\pm$ 1.21%	97.68% $\pm$ 0.94%	99.76% $\pm$ 0.12%	100% $\pm$ 0.00%	75.45% $\pm$ 5.31%	100% $\pm$ 0.00%
4	100% $\pm$ 0.00%	93.57% $\pm$ 0.91%	96.73% $\pm$ 1.33%	100% $\pm$ 0.00%	99.84% $\pm$ 0.14%	78.79% $\pm$ 4.78%	100% $\pm$ 0.00%

4 结论

本文针对复杂电磁环境下干扰信号识别准确率低、单一特征表征能力有限的问题,提出了一种基于自注意力的多模态特征融合网络—MBAFNet。

该网络通过并行处理星座图、循环谱图、功率谱图和频域序列四种模态数据,充分挖掘了干扰信号在多域空间中的互补信息。

MBAFNet在低JNR条件下性能优越的关键原因可归结为三点:一是星座图作为统计特征对噪声

不敏感,提供了稳定的基础判别信息;二是四类模态在物理机理上形成互补,某种模态受干扰时其他模态仍可提供有效判别线索;三是可学习加权融合机制能够根据信噪比动态调整模态贡献,避免了离散模态选择可能造成的信息丢失。实验结果表明,在 $JNR \geq -6$ dB条件下,模型对9类典型干扰信号的识别准确率可达98%以上,验证了所提方法在低干噪比环境下的有效性和鲁棒性。后续将进一步围绕模型轻量化部署、真实测量数据验证以及更复杂电磁环境下的迁移应用等方面展开工作。

参考文献(References)

- [1] 姚富强. 通信抗干扰工程与实践[M]. 第3版. 北京: 电子工业出版社, 2025: 47.
YAO F Q. Communication Anti-jamming Engineering and Practice [M]. 3rd ed. Beijing: Publishing House of Electronics Industry, 2025: 47. (in Chinese)
- [2] CALATRAVA H, TANG S, CLOSAS P. Advances in anti-deception jamming strategies for radar systems: a survey [J]. IEEE Aerospace and Electronic Systems Magazine, 2026, 41(4): 66–93.
- [3] WU Z L, ZHAO Y L, YIN Z D, et al. Jamming signals classification using convolutional neural network [C]//2017 IEEE International Symposium on Signal Processing and Information Technology (ISSPIT). 2017: 062–067.
- [4] WU X J, ZHOU Y B, WU D L, et al. Improved deep residual shrinkage network for intelligent interference recognition with unknown interference [J]. Sensors, 2023, 23(18): 7909.
- [5] TANG Y, ZHAO Z J, CHEN J, et al. Open world recognition of communication jamming signals [J]. China Communications, 2023, 20(6): 199–214.
- [6] QU Q Z, WEI S J, LIU S, et al. JRNet: jamming recognition networks for radar compound suppression jamming signals [J]. IEEE Transactions on Vehicular Technology, 2020, 69(12): 15035–15045.
- [7] WANG P Y, CHENG Y F, PENG Q H, et al. Learning dynamic computing resource allocation in convolutional neural networks for wireless interference identification [J]. IEEE Transactions on Vehicular Technology, 2023, 72(7): 8771–8782.
- [8] LUO Z Y, CAO Y H, YEO T S, et al. SSJR-net: semi-supervised few-shot radar jamming recognition network [J]. IEEE Transactions on Aerospace and Electronic Systems, 2025, 61(5): 12935–12950.
- [9] 陈炽根, 彭启航, 徐俊如, 等. 基于多任务学习的干扰认知方法[J]. 电子科技大学学报, 2025, 54(6): 896–905.
CHEN C G, PENG Q H, XU J R, et al. A jamming cognition approach based on multi-task learning [J]. Journal of University of Electronic Science and Technology of China, 2025, 54(6): 896–905. (in Chinese)
- [10] WANG D Y, DU L S Y, LI Z, et al. WPMNet: weight pruning and parameter quantization assisted multi-scale lightweight network for interference recognition [J]. IEEE Transactions on Cognitive Communications and Networking, 2026, 12: 1313–1326.
- [11] WANG P Y, HUANG X, ZHANG H J, et al. Intelligent wireless interference recognition: challenges, opportunities, and future directions [J]. IEEE Wireless Communications, 2025, 32(6): 209–215.
- [12] LIU M Q, LIU Z L, LU W D, et al. Distributed Few-Shot Learning for Intelligent Recognition of Communication Jamming [J]. IEEE Journal of Selected Topics in Signal Processing, 2022, 16(3): 395–405.
- [13] 杨渡佳, 张欣然, 宋常建, 等. 基于多模态异构小波分解神经网络的干扰样式识别[J]. 通信学报, 2025, 46(10): 150–162.
YANG D J, ZHANG X R, SONG C J, et al. Jamming style recognition based on multimodal heterogeneous wavelet decomposition neural networks [J]. Journal on Communications, 2025, 46(10): 150–162. (in Chinese)
- [14] YAN H L, WANG G P, GAO F F, et al. Dynamic convolutional neural network for wireless interference identification [J]. IEEE Communications Letters, 2024, 28(1): 83–87.
- [15] WANG P Y, MA K, BAI Y S, et al. Wireless interference recognition with multimodal learning [J]. IEEE Transactions on Wireless Communications, 2024, 23(12): 18576–18591.
- [16] 王珣, 吴志强, 刘明骞. 基于ViT网络模型自注意力机制的干扰类型分布式识别方法[J]. 兵工学报, 2025, 46.
WANG X, WU Z Q, LIU M Q. A Distributed Recognition Method for Interference Types based on the Self-attention Mechanism of ViT Network Model [J]. ACTA ARMAMENTARII, 2025, 46. (in Chinese)
- [17] 田弘宇, 葛松虎, 郭宇, 等. 低干噪比下多特征融合的通信干扰识别方法[J]. 系统工程与电子技术, 2025.
TIAN H Y, GE S H, GUO Y, et al. Interference recognition method based on multi-feature fusion under low INR conditions [J]. Systems Engineering and Electronics, 2025. (in Chinese)
- [18] ZHOU S C, ZHANG Y, ZHU L D, et al. Wireless interference recognition based on multimodal feature fusion [J]. IEEE Communications Letters, 2026, 30: 477–481.
- [19] ZHANG Z H, AN J P, YE N, et al. Multi-domain fusion for high-sensitivity interference identification: a lightweight model using multi-scale extraction and compression [J]. IEEE Transactions on Cognitive Communications and Networking, 2026, 12: 2675–2689.
- [20] LIANG W X, TADESSE G A, HO D, et al. Advances, challenges and opportunities in creating data for trust-worthy AI [J]. Nature Machine Intelligence, 2022, 4(8): 669–677.
- [21] LI J Y, MOHAMED A, ZWEIG G, et al. LSTM time and frequency recurrence for automatic speech recognition [C]//2015 IEEE Workshop on Automatic Speech Recognition and Understanding (ASRU). 2015: 187–191.