

基于多模态异构小波分解神经网络的干扰样式识别

杨渡佳^{1,2}, 张欣然¹, 宋常建^{1,2}, 王健¹, 王伦文¹, 朱然刚¹

(1. 国防科技大学电子对抗学院, 安徽 合肥 230037; 2. 合肥综合性国家科学中心信息安全研究中心, 安徽 合肥 230051)

摘要: 在复杂电磁环境中, 准确识别干扰样式, 进而据此调整通信策略, 是提升军民领域通信系统抗干扰能力和保障通信质量的关键环节。针对复杂电磁环境中干扰信号类型识别难、传统神经网络特征提取单一和低于信比信号适应性不足的问题, 提出一种基于多模态异构小波分解神经网络的干扰样式识别模型。该模型利用多模态特征提取框架, 融合信号的时序、频谱幅度与瞬时特征, 通过融合残差机制、双向长短期记忆网络与多尺度小波分解网络三级级联架构实现深度特征挖掘, 同时结合通道注意力机制, 构建全面的特征表征。实验结果表明, 所提模型在识别准确率、少样本以及低干信比条件下的鲁棒性等方面均明显优于近年来该领域先进的异构神经网络模型。

关键词: 干扰识别; 多级异构网络; 多模态特征提取; 多尺度小波分解

中图分类号: TN91

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2025178

Jamming style recognition based on multimodal heterogeneous wavelet decomposition neural networks

YANG Dujia^{1,2}, ZHANG Xinran¹, SONG Changjian^{1,2}, WANG Jian¹, WANG Lunwen¹, ZHU Rangang¹

1. School of Electronic Countermeasures, National University of Defense Technology, Hefei 230037, China

2. Hefei Comprehensive National Science Center Information Security Research Center, Hefei 230051, China

Abstract: In the complex electromagnetic environment, accurately identifying the interference pattern and then adjusting the communication strategy accordingly are the key links to enhance the anti-interference capability of communication system and ensure the communication quality in the military and civil fields. Aiming at the problems of difficult identification of interference signal type in complex electromagnetic environment, single feature extraction of traditional neural network and insufficient adaptability of low dry signal ratio, an interference style identification model based on multimodal heterogeneous wavelet decomposition neural network was proposed. Based on a multimodal feature extraction framework, the proposed model integrated temporal, spectral, and transient features of the signal. A residual mechanism, a three-level cascaded bidirectional long short-term memory (Bi-LSTM), and a multi-scale wavelet decomposition network were incorporated to achieve deep feature mining, while a channel attention mechanism enhanced feature representation. Experiments demonstrate that the model outperforms traditional residual networks and recent heterogeneous models in accuracy, sample efficiency, and robustness under low dry-to-signal ratio conditions.

Keywords: jamming recognition, multi-level heterogeneous network, multimodal feature extraction, multiscale wavelet decomposition

收稿日期: 2025-08-13; 修回日期: 2025-10-05

通信作者: 张欣然, zhangxinran22@nudt.edu.cn

基金项目: 电磁空间安全全国重点实验室基金项目(No.KY25T404)

Foundation Item: The National Key Laboratory of Electromagnetic Space Security (No.KY25T404)

0 引言

随着时代的发展,城市环境中通信设备部署密度持续增加,信号类型日趋多样。不同生活场景下通信设备所使用的频段出现高度重叠,军用与民用频段之间亦存在交叉与占用现象,导致频谱资源竞争加剧、相互干扰问题日益突出。在军用中,敌方常针对我方关键通信节点实施有意干扰,造成通信链路中断,显著降低通信系统的可靠性与稳定性。因此,在复杂的电磁对抗环境中,准确地识别干扰类型,进而以此生成相应的通信抗干扰与安全策略,对保障通信质量和提升系统生存能力具有重要意义^[1-2]。

早期通信干扰样式识别依赖专家知识与特征工程。前者通过构建知识库并提取干扰信号的关键特征实现分类^[3-5];后者则基于统计理论,涵盖决策树^[6]、支持向量机^[7]等方法构建分类器。然而,这些方法存在知识获取耗时费力、领域依赖性强、难以适应领域变更及处理复杂非线性问题能力有限等问题。随着人工智能技术发展,神经网络和深度学习在模式识别领域取得成就,如搭建卷积神经网络^[8-9]、长短时记忆网络提取特征^[10-11],引入注意力机制网络^[12]等。但是传统单一神经网络模型受制于其固定的特征映射机制,所提取的特征往往被局限于单一特征空间或局部特征域,难以有效刻画干扰信号内在的多维耦合特征。

随着大数据时代的加速演进,对多源异构数据的处理与融合需求呈现出持续增长的态势。异构神经网络得益于支持整合多种类型模型的特点,拥有更为出色的泛化表征能力。邵正途等^[13]提出了一维残差-长短期记忆网络(CNN-LSTM)混合网络,通过深度融合时域特征提取与时序建模能力,在0 dB 噪声比下实现了较高的雷达干扰识别准确率。Wang等^[14]创新性地提出全局性引入卷积神经网络(BGCNN, bring globality into convolutional neural network),采用时频图像作为输入模态,将Transformer的全局自注意力机制引入卷积神经网络架构,并结合多尺度融合机制,有效解决了无线干扰分类中远距离依赖建模的难题。Fang等^[15]提出了并行卷积-循环神经网络(CNN-RNN)联合网络架构,通过同时处理时频图像和信号序列数据,显著提升了干扰识别准确率并增强了模型对噪声比分布的泛化能力。Wu等^[16]构建卷积-双向长短时-通道注意力网络(CNN-BiLSTM-SE)模型,抓取并

增强整体包络及时序特征,使平均识别率较CNN-LSTM有所提高。多级异构模块可实现数据特征的多层次自动化提取,能够聚焦于关键特征,深入挖掘数据的高级抽象特征,提升特征表达的精准度与效率。然而,上述方法大多采用单一模态输入,仅能从单一维度感知原始数据,难以全面捕捉数据初始信息,容易导致部分数据信息丢失,限制了对数据深度特征的挖掘。

多模态特征提取指从不同模态的数据中提取出关键的特征信息,并将这些特征加以融合或者关联起来,进而达成对多模态数据进行统一理解以及处理的过程^[17]。Qi等^[18]通过融合时域、频谱及瞬时信息,首次将多模态融合技术应用于模式识别。Zheng等^[19]通过短时傅里叶变换融合双模态信息,利用Transformer架构在低信噪比下实现高准确率信号调制识别,对本文干扰识别有借鉴意义。Wang等^[20]提出了多域网络模型,通过融合时频图像与频域序列的双域信息,结合CNN-Transformer混合架构与3种特征融合机制,显著提升了低干噪比条件下的无线干扰识别性能。Deng^[21]通过联合时域、频域、幅度等模态,提高了对高阶信号的分类准确率。Liu等^[22]融合原始信号与人工提取的特征统计量双模态信息,在低信噪比条件下显著提高识别准确率。Zha等^[23]结合时频图和增强的星座图2种模态作为输入,相较于原始方法准确率显著提高。Zhang等^[24]通过提取原始同向与正交(IQ, in-phase and quadrature)信号、瞬时幅度、相位和频率特征,融合时域和频域模态,识别准确率显著高于基线模型。Shao等^[25]引入IQ信号与短时傅里叶变换(STFT)时频矩阵双模态输入,结合时域和频域特征,提升低信噪比下的识别效果。Mehr等^[26]提出一种特征辅助的CNN分类器(FACC, feature-aided CNN classifier),通过融合输入时频图像与多维统计特征双模态,并利用残差网络进行后续特征提取,在低功率干扰条件下实现了较高的全球导航卫星系统(GNSS)干扰分类准确率。这些技术通过整合不同信息,可以形成全面特征表示,进而弥补单一模态不足,提高模型性能。

随着提取特征维度的不断深入,研究人员提出多尺度小波提取机制。该机制基于提升方案,其核心思想是通过逐步优化简单的初始多分辨率分析,

动态调整小波的属性^[27]。Zhang等^[28]利用自适应小波网络(AWN)替代传统基函数,提升了特征分解能力与识别精确率。Quan等^[29]结合自适应小波分解与深度可分离卷积,在2个数据集上的平均准确率均超过原有模型。Qin等^[30]融合1D、2D卷积与小波分解,增强时空特征捕捉,总体准确率有所提高。多尺度小波分解通过可学习卷积核自适应提取频率信息,增加分解级数可获取更复杂特征,对模型深层次特征挖掘意义重大。本文主要研究工作如下。

1) 针对单一模态提取序列信息有限、限制网络提取特征上限的问题,本文提出多模态特征提取机制,实现了多模态特征的提取与融合。

2) 针对单一神经网络只能从单一维度提取特征的问题,本文提出多级异构模块,实现了干扰序列时空特征的全面表示。

3) 针对传统神经网络无法有效识别频域特征的问题,本文提出多尺度小波分解机制,实现了各频率分量的自适应提取。

4) 仿真结果表明,多模态异构小波分解神经网络(MHWDNN, multimodal heterogeneous wavelet decomposition neural network)在11种干扰样式的数据集下较BGCNN、FACC等异构模型的识别准确率更高,且在少样本和低干信比条件下的鲁棒性更强。

1 干扰数据集

实验采取将干扰信号、通信信号与背景白噪声混叠在真实无线电磁环境下模拟现实中的通信场景。实验中通过VSG60设备产生干扰信号模拟不同强度和样式的干扰信号。为确保实验条件的严谨性与科学性,本文对实验参数进行了设置,将背景噪声强度控制在 -85 dBm左右,通信信号强度设定为 -50 dBm左右。本文将VSG60产生的干扰分为模拟干扰和数字干扰2类。模拟干扰包括单音、多音、噪声调频、脉冲、阶跃扫频、斜坡扫频及白噪声类型;数字干扰则涵盖八相移键控(8PSK)噪声调制、十六相移键控(QAM16)噪声调制和四频移键控(4FSK)噪声调制类型。除此以外,还引入一组具有实际应用背景的无人机链路控制Wi-Fi调制干扰信号。综上,实验所涉及的干扰类型总数达11种,充分涵盖了多种可能面临的真实干扰场景。实验使用2个某型对讲机作为通信设备,模拟

正常通信信号。该对讲机的工作频段限定于 $400\sim 430$ MHz,相邻频率通道间隔为 25 kHz,调制方式选用FM。实验采集的电磁数据为IQ数据,且采样点数量为 $8\ 192$,因此将输入的原始电磁数据保存为 $8\ 192\times 2$ 的格式。

信号采集采用无人机机载侦察接收设备,干扰信号的产生与采集流程如图1所示。



图1 干扰信号的产生与采集流程

在构建数据集方面,本文将每个类别的训练样本随机划分为3个量级的数据集,分别约为 600 、 $1\ 200$ 、 $2\ 400$ 。通过这些不同量级的样本集,可以衡量模型在不同规模数据样本下的识别性能,从而有效应对现实环境中数据量不足的普遍问题。在数据分配上,对11种干扰类型的数据按照 $8:1:1$ 的比例随机划分训练集、验证集及测试集。这一分配策略旨在保障模型能够深度学习、精准验证并客观评估,进而增强其鲁棒性,确保模型在实际应用中的有效性和可靠性。

2 MHWDNN模型

针对传统网络提取特征维度单一、单一模态获取序列信息不足、各模态特征贡献度难以区分、传统网络难以有效提取信号频域特征4个科学问题,本文提出了MHWDNN架构,该架构由多模态特征提取模块、多级异构模块和多尺度小波分解模块三大核心部分构成,如图2所示。输入的干扰信号 $r[n]$ 首先被提取为时域、谱幅和瞬时信息,分别对应时序、谱幅和瞬时3个模态的模态序列 $r_1[n]$ 、 $r_2[n]$ 、 $r_3[n]$ 。接着,这些序列经特征嵌入层提取特征后融合得到 F_4 ,该特征经过多级异构模块处理后得到 F_6 。 F_6 经过多尺度小波分解模块处理,生成多级细节分量和最后一级近似分量,拼接得到多级频率特征,并经通道注意力生成通

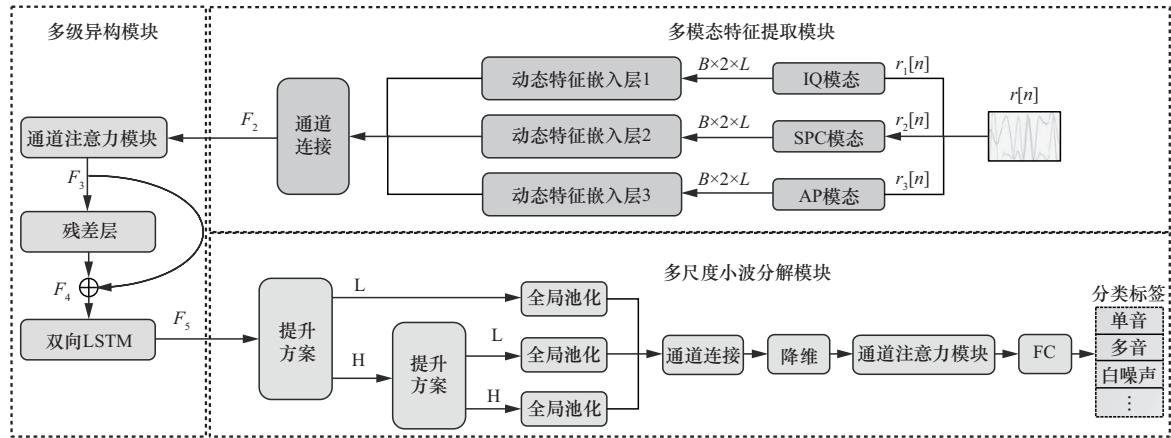


图2 MHWDNN架构

道权重, 最终输出分类标签概率。下面分别对各模块的模型流程进行分析。多模态特征提取模块模型参数如表 1 所示。

表 1 多模态特征提取模块模型参数

参数	含义
$r[n], r_1[n], r_2[n], r_3[n]$	原始干扰信号、IQ 模态序列、SPC 模态序列、AP 模态序列
$F_{fp}, F_{fpp}, F_{amp}, F_{phase}$	频谱幅度序列、平方谱幅度序列、瞬时幅度序列、瞬时相位序列
F_2, F_3, F_4	3 种模态中间特征拼接值、经过通道注意力生成的通道加权特征、经过特征融合层生成的各模态融合特征
F_5, F_6	融合特征经过残差连接层得到的空间特征经 BiLSTM 提取的时空特征表示
$w, L^{(i)}, H^{(i)}$	小波分解层数、上级分解所得低频分量、上级分解所得高频分量
$L_o^{(i)}, L_c^{(i)}, P, U$	第 i 级分解输入特征积分量、偶分量、预测器、更新器
B, L	模型一次处理的数据样本数量、每个样本序列的长度

2.1 多模态特征提取模块

如图 2 所示, 多模态特征提取模块包含: 用于生成各模态序列的模块、3 个动态特征嵌入层、通道注意力层和特征融合层。下面对各部分的结构与功能进行介绍。

2.1.1 干扰信号序列多模态构建

原始干扰信号 IQ 模态由实部和虚部构成, 可由式(1)表示。

$$\begin{cases} I[n] = \text{real}(r[n]) \\ Q[n] = \text{imag}(r[n]) \\ r_1[n] = [I[n]; Q[n]] \end{cases} \quad (1)$$

频谱幅度和平方谱幅度 (SPC, spectral amplitude and squared signal's spectral amplitude) 模态的计算式为

$$\begin{cases} F_{fp}[k] = \left| \sum_{n=1}^N r[n] e^{-\frac{j2\pi kn}{N}} \right| & k = 0, 1, 2, \dots, N-1 \\ F_{fpp}[k] = \left| \sum_{n=1}^N r^2[n] e^{-\frac{j2\pi kn}{N}} \right| & k = 0, 1, 2, \dots, N-1 \\ r_2[n] = [F_{fp}[n]; F_{fpp}[n]] \end{cases} \quad (2)$$

瞬时幅度与相位 (AP, instantaneous amplitude and phase) 模态的计算式为

$$\begin{cases} F_{amp} = \frac{|r[n]|N}{\sqrt{\sum_{n=1}^N |r[n]|^2}} & n = 1, 2, 3, \dots, N \\ F_{phase} = \arctan \frac{I[n]}{Q[n]} & n = 1, 2, 3, \dots, N \\ r_2[n] = [F_{amp}; F_{phase}] \end{cases} \quad (3)$$

模型流程具体而言, 输入端干扰信号 $r[n] \in \mathbb{R}^{B \times 2 \times L}$ 首先通过提取不同维度特征生成 3 个模态的干扰序列 $r_1[n] \in \mathbb{R}^{B \times 2 \times L}$ 、 $r_2[n] \in \mathbb{R}^{B \times 2 \times L}$ 、 $r_3[n] \in \mathbb{R}^{B \times 2 \times L}$ 。3 种模态的序列信息起到互补作用, 对于提升网络性能具有重大意义。

2.1.2 动态特征嵌入层

动态特征嵌入层对生成的 3 种模态序列分别做初步特征提取得到 IQ 特征、SPC 特征与 AP 特征。最后通过嵌入层层将 3 个特征在通道维度拼接起来, 得到 $F_2 \in \mathbb{R}^{B \times \frac{3}{8}D \times L}$, 其中动态特征嵌入层的网络结构如图 3 所示。




图3 动态特征嵌入层的网络结构

动态特征嵌入层采用深度卷积。深度卷积作为特殊形式的分组卷积，其分组数与输入通道数相等，比普通卷积显著减少了计算量和参数量。

2.1.3 通道注意力层

拼接后的特征被输入通道注意力模块，当输入 F_2 传递至通道注意力模块时，初步操作是在最后一个维度上执行全局平均池化过程。池化操作浓缩原始空间信息并保留通道信息，中间特征经 2 个线性层实施通道变换，先扩大通道数以降低计算复杂度、提取更紧凑特征表示，再恢复通道数匹配后续权重乘法。将通道变换后的特征进一步输入到 Sigmoid 激活函数以生成通道权重，其通过广播机制扩展后与 F_2 逐元素相乘得到最终经过通道加权的特征 $F_3 \in \mathbb{R}^{B \times \frac{3}{8}D \times L}$ 。通道注意力模块网络结构如图 4 所示。

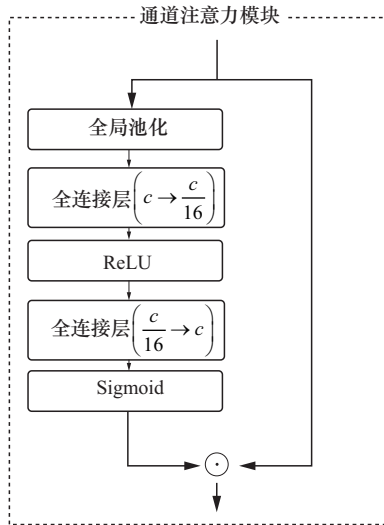


图4 通道注意力机制网络结构

2.1.4 特征融合层

经过加权的特征 F_3 随后被输入特征融合层，

通过一维卷积进行维度交换与特征整合，在保留空间信息的同时进行通道维度变换，通过卷积核尺寸为 1 的操作实现特征加权及 3 种模态通道特征的交互融合。特征融合层经过 2 个逐点卷积与 GeLU 激活函数得到特征 $F_4 \in \mathbb{R}^{B \times \frac{3}{4}D \times L}$ 。特征融合模块的网络结构如图 5 所示。

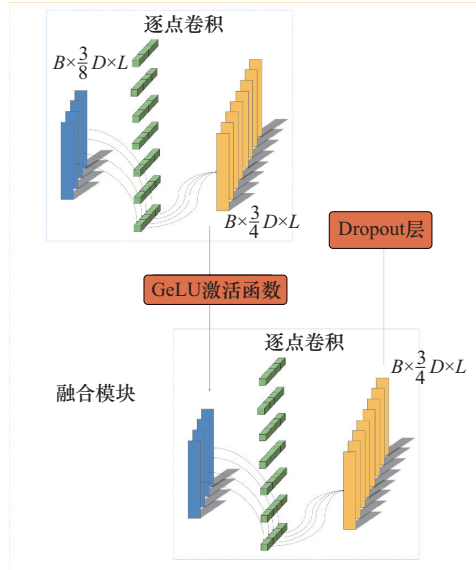


图5 特征融合模块的网络结构

特征融合层将提取各模态通道的初步特征进行融合，整合多模态数据优势，为后续多级异构模块奠定基础，助力其挖掘更深层次、更具判别性的特征，从而提升模型的性能与泛化能力。

2.2 多级异构模块

多级异构模块由残差连接层与 BiLSTM 组成。残差连接可提供梯度传输通道，避免反向传播中的梯度消失；BiLSTM 通过 RNN 门控机制学习中间特征时间关系，提取时序特征。在残差模块设计中，本文采用三阶段残差架构替代传统残差模型，通过简化网络结构降低计算复杂度与过拟合风险，在保持模型性能的同时优化资源消耗，有效匹配特定数据集的复杂性需求。

残差模块首先利用大卷积核 ($k=7$) 对输入数据进行初步特征提取，较大步长可减小特征图尺寸，降低计算复杂度，同时保留关键特征信息。然后采用核大小为 4 的最大池化层进一步下采样，降低特征空间维度，减少计算量并增强平移不变性。接着引入三阶段残差连接机制，每个阶段包含 2 个卷积核大小为 3 的一维卷积层，逐步捕捉细微特征

并进一步减小特征图尺寸,显著提高计算效率和模型泛化能力。

输入特征 F_4 经过残差层提取序列空间信息后得到中间特征 $F_5 \in \mathbb{R}^{B \times 256 \times \frac{L}{16}}$, 随后将其送至双向长短期记忆网络以实现上下文信息的集成。具体而言, BiLSTM 由 2 个独立的 LSTM 单元构成: 一个单元负责正向处理序列数据, 沿着时间序列的自然顺序捕捉特征; 另一个单元则负责反向处理序列数据, 从时间序列的末端向起点进行特征提取。这 2 个方向的处理结果相互补充, 共同作用生成包含完整时间序列信息的特征 $F_6 \in \mathbb{R}^{B \times 256 \times \frac{L}{16}}$, 从而为后续的分析任务提供更丰富的时序特征。

2.3 多尺度小波分解模块

将多级异构模块的输出特征 F_6 输入多尺度小波分解模块, 对序列进行进一步的频率特征提取。本模块中小波自适应分解属于二代小波变换, 其结构如图 6 所示。

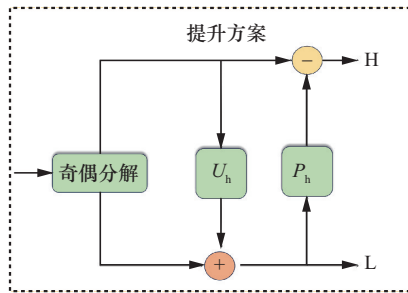


图 6 多尺度小波分解模块结构

假设小波分解共有 w 层, 则输入特征在第 i 层首先被分为奇偶 2 个分量, 通过更新器 U 和预测器 P 作用生成低频近似分量与高频细节分量, 其计算式为

$$\begin{cases} [L_o^{(i)}, L_c^{(i)}] = \text{split}(L^{(i)}) \\ H^{(i+1)} = L_o^{(i)} - P(L_c^{(i)}) \\ L^{(i+1)} = L_c^{(i)} + U(H^{(i+1)}) \end{cases} \quad (4)$$

其中, $L_o^{(i)}$ 和 $L_c^{(i)}$ 分别表示输入特征的积分量与偶分量, 输入特征为上一级分解得到的低频分量 $L^{(i)} \in \mathbb{R}^{B \times D \times \frac{L}{2^i}}$, 而对应分解得到的高频分量为 $H^{(i)} \in \mathbb{R}^{B \times D \times \frac{L}{2^i}}$ 。在提升方案中预测器和更新器尤为重要, 传统小波变换中这 2 个参数为定值, 但本文设计为可训练参数参与梯度下降, 其网络结构如图 7 所示。




图 7 预测器和更新器网络结构

图 7 中预测器与更新器都先进行反射填充。所谓反射填充, 即在特定维度以输入数据的边缘为对称轴沿着特定方向向外反射特定长度, 这样可以使得填充后的数据在边缘处具有一定的连续性和对称性, 避免引入额外的不相关信息, 减少因零填充带来的边界效应。以第 i 次分解的预测器为例, 输入特征为上一级分解的低频分量经过分割操作得到的偶分量 $L_c^{(i)} \in \mathbb{R}^{B \times D \times \frac{L}{2^{i+1}}}$, 对该分量反射填充后经过 2 个 $k=3$ 的一维卷积层提取序列中的抽象特征, 最后经过 Tanh 层得到动态权重。

经过 w 级分解后共有 w 个高频分量 $H^{(1)}, H^{(2)}, \dots, H^{(w)}$ 和第 w 级的低频分量 $L^{(w)}$, 将上述特征统一输入平均池化层后在通道维度进行连接, 再经过降维后通过通道注意力模块生成通道权重以学习每个频率分解的重要性。最后将经过通道加权处理后的频率特征输入至全连接层中, 进而得到各分类标签的预测概率。

2.4 正则化机制

为使模型复杂度与数据匹配, 训练过程引入正则化方法。本文使用的模型损失函数为分类损失与提升方案损失之和, 其中提升方案损失由各级细节损失与近似损失组成, 其形式可表示为

$$L = L_c + \lambda_1 \sum_{i=0}^{w-1} |\bar{H}^{(i)}| + \lambda_2 \sum_{i=0}^{w-2} \|\bar{L}^{(i)} - \bar{L}^{(i+1)}\|_2 \quad (5)$$

其中, L_c 为分类损失, 后两项分别用来最小化高频细节损失与维持低频近似系数, 可以看出细节分量采用 L1 正则化, 近似分量采用 L2 正则化。 λ_1 和 λ_2 为调节正则化强度的超参数, $\bar{H}^{(i)}$ 和 $\bar{L}^{(i)}$ 示对各自分量取平均。

2.5 前向传播伪代码

前向传播是指输入数据在一个批次内在网络中逐层传递并最终产生输出的过程。根据前文分析, 算法前向传播的流程如下。

1) 3 种模态序列 $r_1[n], r_2[n], r_3[n]$ 通过多模态特征提取并拼接生成 F_2 , 经过通道注意力机制

加权得到 F_3 ，经特征融合模块得到 F_4 。

2) 得到的融合特征输入多级异构模块，该特征经过三层残差连接生成 F_5 ，再通过双向 LSTM 时序建模生成 F_6 。

3) 将所提取的时空特征输入多尺度小波分解模块进行 w 级分解，根据式(4)每级分解时前一级特征 \mathcal{F} 先进行奇偶分解，用所得奇偶分量进行预测更新，生成一系列低频近似分量 L_i 和高频细节分量 H_i 。将各级高频分量与最后一级低频分量全局池化后连接后输入通道注意力层，得到特征 f 。

4) 计算分类标签 y_i 与最终输出特征 \hat{y}_i 的交叉熵损失，根据式(5)计算提升方案损失，进而得出前向传播总损失，最后计算反向传播误差并更新模型权重。

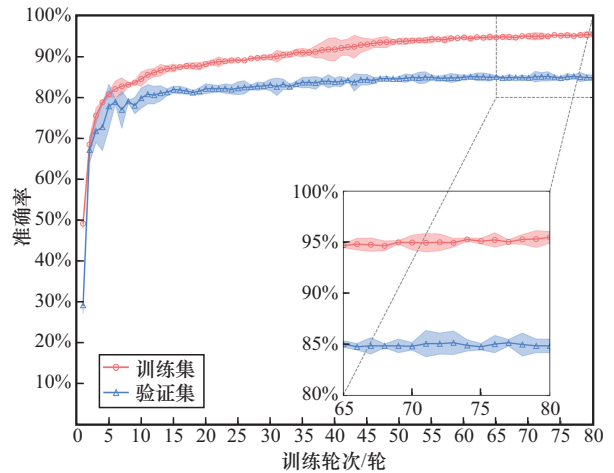
上述流程展示了 MHWDNN 模型的一次单向传播过程，揭示了数据传递流向，明晰了 MHWDNN 模型的内部工作机制。MHWDNN 模型中 3 个模态的数据首先进入特征嵌入层，完成初步特征提取后，经由带有通道注意力的特征融合层实现三通道特征的混叠，随后通过残差模块进一步提取深度空间特征，再输入至 BiLSTM 层以获取时序特征。将得到的中间特征进行多尺度小波分解，把各高频分量与最后一级低频分量连接，并通过通道注意力生成权重，最终输入全连接层生成分类标签概率。同时计算反向传播误差，依据梯度下降法更新模型权重，从而完成一个批次数据的前向与反向传播过程。

3 性能测试与分析


3.1 模型训练与可视化

为确保训练稳定性，本文对每组样本用 3 个随机种子重复实验，计算准确率和损失率的均值与标准差，生成含置信区间的训练信息图。以每种类别 600 个样本为例，绘制出全干信比上模型验证集准确率曲线、损失率曲线、精确率、召回率与 F1 值变化曲线如图 8 所示。


图 8 阴影区域表征了基于 3 种子模型训练各轮次性能指标标准差所计算的 95% 置信区间。在每种干扰类别 600 个样本构成的训练集上，模型经过 80 轮迭代训练后，其在验证集上的识别准确率呈现稳定上升趋势，最终达到 84.85% 的水平。同时，随着训练轮次的持续推进，训练集损失与验证集损失均持续递减，模型性能及预训练效果逐渐趋于收敛，预示模型参数学习趋于稳定。



(a) 每种干扰类别 600 个样本训练过程验证集准确率曲线



(b) 每种干扰类别 600 个样本训练过程验证集损失率曲线



(c) 每种干扰类别 600 个样本训练过程验证集其他参数曲线

图 8 验证集准确率、损失率与其他评估参数变化曲线

为评估分类模型性能，实验采用精确率、召回率与 F1 值作为核心指标。在图 8(c) 中，训练初期各指标迅速上升，表明模型具有较强的梯度优化与特征学习能力。随着训练推进，指标增长渐缓并最终

稳定在 84% 以上, 说明模型逐渐收敛, 逼近训练集上的性能极限, 同时在判别准确性与样本召回率之间达到良好平衡, 体现出较优的泛化能力与数据适应性。

实验为研究模型对每一种干扰样式的分类情况, 并分析样本数量对其影响, 以每种干扰类别 2 400 个样本为例, 用测试集结果生成混淆矩阵如图 9 所示。




图 9 每种干扰类型 2 400 个样本的混淆矩阵

图 9 中每种干扰类别 2 400 个样本条件下模型在测试集上分类准确率可达 95.51%, 展现出良好的整体分类性能。从图 9 可以看出, 对角线元素明显颜色要深于其余部分颜色, 表明模型分类准确率较高。模型对于数字调制、Wi-Fi 调制、白噪声、斜坡扫频、多音这些频谱特点较为明显的干扰类型可实现完美识别, 达到 98% 以上; 对于噪声调频干扰和脉冲干扰的识别效果不佳, 仅为 90% 左右。此外, 还可以看出, 约有 10% 的单音和阶跃扫频会被识别为脉冲干扰。这是由于脉冲干扰设置频谱较宽, 在某些频点上与单音干扰类似; 而阶跃扫频在频率突变过快时, 其时域突变点与脉冲干扰较为类似。

为进一步衡量模型对各样本的分类效果, 以每种干扰类别 2 400 个样本点为例对测试集的分类结果进行 t-SNE 降维得到二维嵌入图如图 10 所示。

t-SNE 降维模型生成的二维嵌入图显示了各类干扰数据在特征空间中呈现出显著的聚类态势。从图 10 可以看出, 代表不同类别的数据点各自聚合形成高度内聚且空间分离的独立簇群, 各簇边界清

晰锐利, 类间间隔明显。这种强空间可分性直观地印证了模型分类结果的可靠性, 表明 MHWDDNN 模型能够精准解耦并有效区分不同类别的干扰特征模式。该可视化证据充分证实了模型在特征解译与模式辨识方面的优势, 特别是特征判别能力与分类鲁棒性, 为复杂干扰场景下的高精度分类任务提供了可靠的技术支撑。




图 10 每种干扰类型 2400 个样本点时 t-SNE 二维嵌入图

3.2 编码长度与模型性能分析

在分类任务中, 神经网络的深度与其识别性能显著相关, 而编码长度则是网络深度的集中表征。编码过短易致训练不足, 难以逼近理想精度; 编码过长则诱发过度特征抽取, 引发过拟合。本文以残差单元的堆叠层数模拟编码长度, 并在每类干扰信号 600 个样本的设定下, 绘制了不同编码长度对应的验证集准确率曲线, 如图 11 所示。

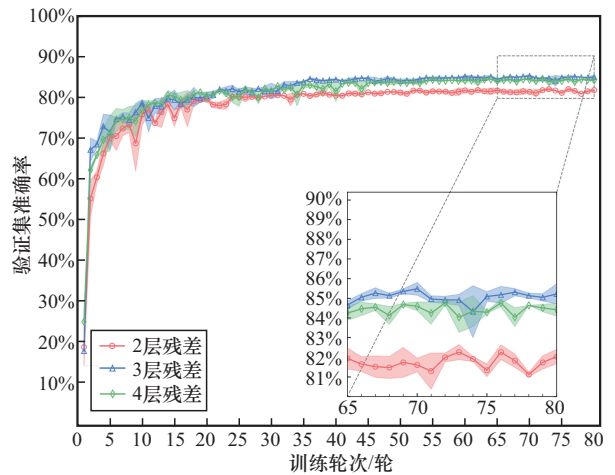


图 11 不同编码长度下验证集准确率曲线

从图 11 可以看出, 在相同实验条件下, 3 层残差结构的验证集准确率高于传统 4 层结构, 表明当

层数不足时，网络难以捕获足够的深度特征；而当层数过多时，模型易陷入过拟合，并伴随计算复杂度的增加。鉴于以上实验结果，本文模型最终选择 3 层残差结构。

3.3 模型对比与模型评估

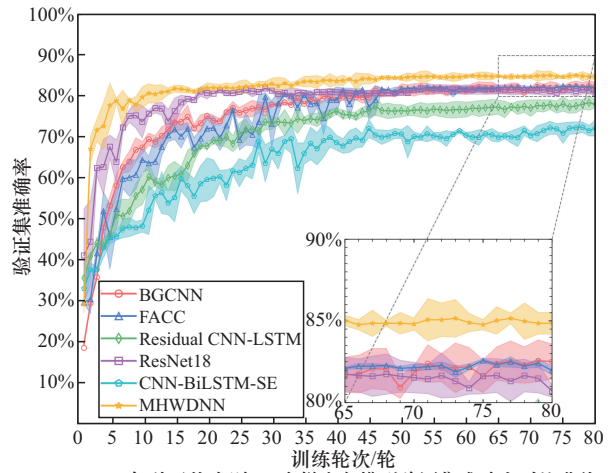
3.3.1 模型准确率对比分析

经系统调研，本文选取近年来干扰识别领域中与本文方法相关且性能较优的模型作为对比基线，包括 BGCNN^[14]、Residual CNN-LSTM^[13]、CNN-BiLSTM-SE^[16]、FACC^[26]，以及基准模型 ResNet18。


所选取对比模型的网络结构与参数在复现时基本沿袭原文，FACC 和 BGCNN 的输入层参数做了适应性调整，以匹配本文数据集。本文将所提模型与对照组在验证集上的表现进行对比。为确保结果可靠稳定，以上模型均用相同的 3 个随机种子初始化，计算准确率和 Kappa 系数的均值与标准差，同时引入 95% 置信区间表征测量值的概率密度分布特性。Kappa 系数通过混淆矩阵计算，可在类别分布不平衡时校正随机一致性，提供更客观的分类评估指标。图 12 展示不同训练样本规模下，各模型在同数据集各训练轮次验证集准确率变化。

从图 12 可以看出，相同训练规模 MHWDDN 的准确率要高于对照组模型。以每种干扰类别 600 个样本点为例，50 轮训练后验证集准确率基本持平 85%，平均高于 BGCNN 和 FACC 3 个百分点。究其原因，BGCNN 通过编码机制考虑了全局性，通过卷积操作提取了空间特征，但输入模态过于单一；FACC 提取多维模态，但后续残差操作只考虑了空间维度，提取特征单一。ResNet18 和 Residual CNN-LSTM 准确率紧随其后，后者增加 LSTM 后反而更低缘于复现模型的数据适应性，模型设置的大核卷积过分关注全局上下文而丢失空间细节信息。CNN-BiLSTM-SE 模型由于缺少残差连接机制在少样本训练规模下精度较差，准确率没有超过 80%。

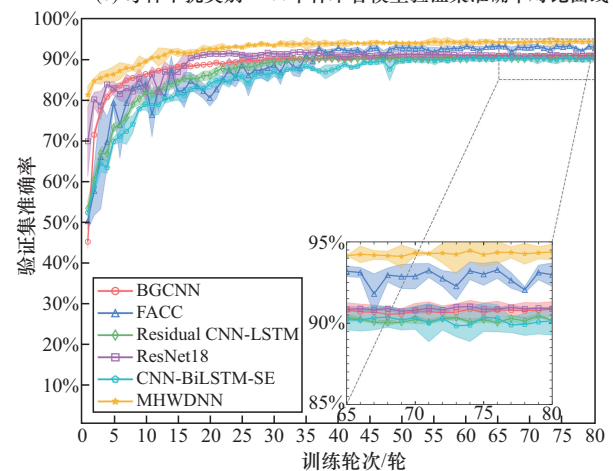
随着数据量增加，各基准模型分类精度均有所提升，但是 MHWDDN 收敛速度最快且最终分类精度最高，而且在少样本条件下优势更明显。随着每种干扰类别样本数量的下降，MHWDDN 准确率仅从 96.93% 降至 87.68%，下降幅度最低，表现出更强的鲁棒性。综上所述，MHWDDN 凭借多模态融合机制和跨维度特征提取能力实现了性能突破。



(a) 每种干扰类别 600 个样本各模型验证集准确率对比曲线



(b) 每种干扰类别 1 200 个样本各模型验证集准确率对比曲线



(c) 每种干扰类别 2 400 个样本各模型验证集准确率对比曲线

图 12 不同样本量条件下各模型与 MHWDDN 验证集准确率对比

为全面评估基准模型性能，在完成 80 轮训练后，本文继续计算 600、1 200 和 2 400 这 3 种样本规模下的准确率和 Kappa 系数 2 项指标。为增强结果可靠性，对每一实验条件均使用 3 个不同随机种子进行重复实验，并统计其实验结果的均值与标准

差。相关性能指标详细统计结果如表 2 所示。对比结果表明,在 11 类干扰样式的识别任务中, MHWDNN 在其中的 7 类上均表现出显著优势,其准确率与 Kappa 系数均为最高,且结果方差最小,体现了最优的综合性能与稳定性。这充分彰显了 MHWDNN 相较其他模型所具备的显著优势,即在多种样本规模及复杂干扰场景下均表现出更优的识别精度与更均衡的分类性能。

3.3.2 模型不同干信比条件对比分析

在电磁干扰识别研究中,背景噪声强度是特征提取的主要瓶颈。低干信比条件下,信噪分离能力下降导致特征混淆,此时识别精度直接体现模型抗噪性能。该指标既可以评估模型在频域特征解耦中的泛化能力,也是筛选抗噪架构的关键依据,对衡量模型在实际电磁环境中的工程适用性具有重要价值。

本文在进行模型训练时,将训练数据集中包含的干信比设定在 0~15 dB 范围区间内,以期模型能够学习并适应不同干扰强度环境下的信号特征。为系统地评估 MHWDNN 在不同干扰强度场景下的鲁棒性能,特别是其应对强干扰的能力,实验将测试集数据划分为 0 dB、5 dB 和 10~15 dB。图 13 通过

柱状图直观地呈现了在不同训练样本数量下各干信比测试子组的模型测试数据识别准确率,以揭示模型识别性能随干信比变化以及随训练样本量增加而产生的显著关联性与演化趋势。图 14 则聚焦于每种干扰类别为 2 400 个样本点时 0 dB 干信比条件下 MHWDNN 与若干典型基准模型在测试集上的准确率对比结果,旨在更清晰地凸显 MHWDNN 在低干扰强度下的优势。




图 13 不同样本数量下各干信比测试数据识别准确率

表 2 各模型与单种干扰样式识别指标统计

样本数量/个	评价指标	ResNet18	BGCNN	Residual CNN-LSTM	CNN-BiLSTM-SE	FACC	MHWDNN
600	准确率	83.28%±3.43%	86.61%±0.87%	82.40%±2.71%	76.46%±2.62%	88.96%±0.45%	89.95%±0.39%
	Kappa×100	81.59±3.77	85.25±0.95	80.62±2.96	74.12±2.86	87.83±0.49	88.92±0.43
1 200	准确率	90.91%±0.76%	91.77%±0.35%	90.23%±0.42%	81.88%±0.44%	92.93%±0.33%	93.31%±0.37%
	Kappa×100	89.99±0.83	90.93±0.39	89.24±0.46	80.02±0.49	91.31±0.36	92.63±0.41
2 400	准确率	92.59%±0.64%	92.74%±0.16%	91.43%±1.20%	90.13%±0.79%	93.31%±0.64%	95.20%±0.26%
	Kappa×100	91.84±0.70	91.91±0.18	90.57±1.32	89.14±0.87	92.74±0.80	94.71±0.28
	单音	90.75%±2.14%	88.16%±0.88%	86.53%±2.33%	78.64%±7.49%	90.61%±0.58%	92.65%±0.33%
	噪声调频	85.57%±1.21%	79.13%±5.09%	85.15%±1.30%	73.81%±1.30%	86.89%±2.63%	91.18%±1.78%
	脉冲	74.58%±7.78%	81.11%±5.30%	83.19%±3.49%	76.67%±4.14%	87.64%±4.44%	85.28%±2.05%
	多音	85.20%±0.21%	99.28%±0.21%	98.55%±0.41%	96.67%±0.41%	92.46%±0.14%	98.84%±0.41%
2 400	阶跃扫频	85.20%±0.97%	87.00%±0.00%	86.10%±0.63%	82.66%±0.76%	87.00%±0.00%	88.04%±0.76%
	斜坡扫频	99.87%±0.19%	100.00%±0.00%	99.22%±0.32%	99.09%±0.19%	100.00%±0.00%	100.00%±0.00%
	白噪声	100.00%±0.00%	100.00%±0.00%	100.00%±0.00%	100.00%±0.00%	99.86%±0.21%	100.00%±0.00%
	8PSK 调制	98.29%±0.60%	90.74%±2.32%	92.31%±1.26%	87.61%±1.40%	90.03%±4.33%	99.00%±0.53%
	QAM16 调制	95.74%±1.36%	95.89%±1.98%	94.86%±1.10%	94.42%±2.70%	93.10%±3.69%	95.45%±1.81%
	4FSK 调制	99.82%±0.26%	100.00%±0.00%	99.82%±0.26%	92.43%±1.92%	100.00%±0.00%	100.00%±0.00%
Wi-Fi 调制	88.93%±0.56%	99.61%±0.32%	90.91%±3.08%	99.47%±0.19%	92.94%±0.49%	97.36%±0.81%	




图 14 2 400 个训练样本数量下干信比为 0 dB 的各模型测试集识别准确率

图 13 与图 14 的实验结果表明随着训练样本量的增加, 所有模型在各干信比条件下的识别准确率均呈单调上升趋势。在少样本场景下, 当干信比由 10~15 dB 降至 0 dB 时, 各模型性能普遍衰减, 其中 MHWDNN 与 FACC 的下降幅度相对较小; 然而, 综合整体准确率与 Kappa 系数可见, MHWDNN 的分类精度与类别均衡性均显著优于 FACC。在全样本训练条件下, MHWDNN 在低干信比时优势更为突出, 其准确率提升幅度显著高于对比模型。上述结果表明, MHWDNN 在复杂电磁干扰环境中具备更强的鲁棒性, 对干扰强度变化表现出更高的识别可靠性与稳定性。

3.3.3 模型推理时间对比分析

在评估模型性能时, 推理时间和参数量同样是不可忽视的关键因素。表 3 展示了各基准模型与 MHWDNN 在推理时间及参数量方面的对比数据。

模型	推理时间/s	FPS	FLOPS	参数量
ResNet18	37.108	26.948	1.407×10^9	3.844×10^6
BGCNN	24.394	40.993	0.124×10^9	0.282×10^6
Residual CNN-LSTM	7.745	129.119	0.083×10^9	1.042×10^6
CNN-BiLSTM-SE	6.317	158.306	0.206×10^9	1.875×10^6
FACC	27.866	35.886	1.745×10^9	11.612×10^6
MHWDNN	22.343	41.080	1.079×10^9	3.057×10^6

为准确评估模型性能, 本文定义推理时间为单次前向传播完整的时长, 测量时先预热 GPU, 再取 20 次推理时间平均值作为最终结果。FPS 为模型

吞吐量的关键指标, FLOP 衡量单次推理计算复杂度, 参数量则是指模型中可训练参数的总数。

对比表 3 同时结合表 2 可以看出, MHWDNN 的单次推理耗时虽略高于 CNN-BiLSTM-SE 与 Residual CNN-LSTM, 这是由于这 2 种模型缺乏多模态输入, 异构方式较为简单, 但 MHWDNN 在动态场景中的识别精度明显更高。此外, MHWDNN 的残差连接层数较传统残差网络更少, 即参数量更少、推理更快。因此, 综合考虑模型计算开销和推理性能, MHWDNN 具有最好的综合性能。

3.4 消融分析

为分析 MHWDNN 的各模块对整体性能的贡献, 本文设计了 6 组消融实验。每组实验仅移除或修改一个特定模块, 其余超参数、数据预处理与训练策略均保持一致。为排除随机性的影响, 每组实验均在 3 个随机种子下独立重复, 以增强实验结果的统计可靠性。图 15 展示了在每类 2 400 个样本的典型场景下, 各消融模型在验证集上的准确率变化曲线。

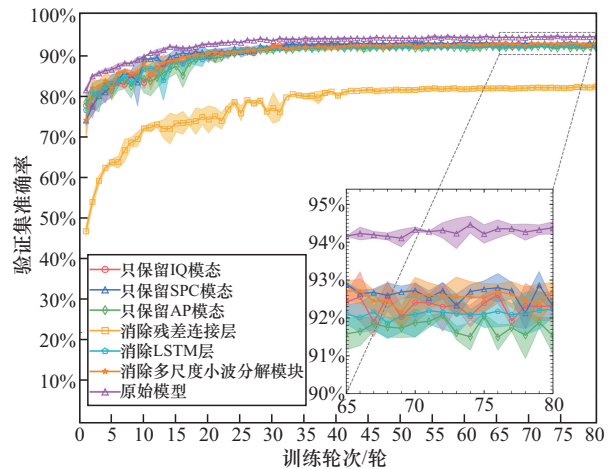


图 15 每种干扰类别 2 400 个样本条件下消融实验验证集准确率

从图 15 可以看出, 原始 MHWDNN 模型在每种干扰类别 2 400 个样本条件下验证集精度达 93.88%, 优于各消融模型, 凸显完整架构的整体优势; 仅保留 IQ、SPC、AP 模态, 经过 80 轮训练模型在验证集上精度分别降低到 92.31%、92.31%、91.53%, 证实多模态特征提取对提升分类精度的关键作用; 移除残差连接、BiLSTM、多尺度小波分解模块后的模型精度分别降低到 82.13%、92.23%、92.71%, 则分别表明残差机制有效缓解梯度消失并提升训练效率, LSTM 在捕捉时序特征方面的重要性以及多尺度小波分解模块在自适应频率特征提取和强化复

杂信号分类能力方面的优势。

表 4 统计了每种干扰类别 2 400 个样本条件下各消融组的测试集准确率和消融系数。

表 4 消融实验测试集准确率与消融系数均值

模型	准确率	Kappa×100
只保留 IQ 模态	94.09%±0.35%	93.84±0.59
只保留 SPC 模态	94.62%±0.83%	94.54±0.91
只保留 AP 模态	93.19%±0.33%	92.90±0.60
移除残差机制	84.95% ±0.34%	82.60±1.10
移除 BiLSTM	94.31%±0.05%	93.88±0.18
移除多尺度小波分解模块	94.18%±0.31%	94.08±0.66
原始模型	95.20%±0.26%	94.71±0.28

消融实验表明,原始模型在所有对比组中均取得最佳分类性能,验证了其架构设计的有效性。该模型通过整合多模态互补信息,并保留残差机制、BiLSTM 与多尺度小波分解等核心模块,实现了多源异构特征的高效协同与深层抽象,从而在分类准确率与模型容量等关键指标上保持领先。

具体而言,不同模态对性能贡献存在差异:IQ 与 SPC 模态在当前样本条件下区分性更强,AP 模态则较弱。不同模块的作用亦不相同:移除残差机制使准确率由 95.20% 降至 84.95%,表明其有效缓解了梯度消失,增强了特征学习能力;移除 BiLSTM 后准确率降至 94.31%,体现出该结构在时序特征提取与上下文建模中的重要价值。

4 结束语

针对复杂电磁环境下干扰识别难的问题,本文提出了一种多模态异构小波分解神经网络。该网络首先利用多模态特征提取模块融合多模态信息,接着通过多级异构模块提取干扰数据的空间与时域特征,最后借助多尺度小波分解模块自适应地提取信号的多频率特征,实现信号的多维度抽象特征表征。与近年来干扰识别领域先进模型的对比实验表明,MHWDNN 在识别精度、低信噪比和少样本鲁棒性方面具有显著优势。消融实验也进一步证实模型各模块均发挥着不可或缺的作用。MHWDNN 能够协助技术人员迅速识别干扰类型,并据此采取相应的抗干扰措施,以保障通信安全可靠。未来,本文将继续研究更复杂的编码模型、多模态结构等改进手段对本模型的影响。

参考文献:

- [1] 马松,李黎,黎伟,等.基于近端策略优化的智能抗干扰决策算法[J].通信学报,2024,45(8):249-257.
MA S, LI L, LI W, et al. Intelligent anti-jamming decision algorithm based on proximal policy optimization[J]. Journal on Communications, 2024, 45(8): 249-257.
- [2] 李刚,吴麒,王翔,等.基于样本信息熵辅助的深度强化学习抗干扰策略[J].通信学报,2024,45(9):115-128.
LI G, WU Q, WANG X, et al. Deep reinforcement learning-empowered anti-jamming strategy aided by sample information entropy[J]. Journal on Communications, 2024, 45(9): 115-128.
- [3] 陈自力,韦乃棋,朱安石.基于分数阶 Fourier 变换的宽带干扰识别方法[J].电光与控制,2013,20(10):102-105.
CHEN Z L, WEI N Q, ZHU A S. Identification of wide-band jamming based on FRFT[J]. Electronics Optics & Control, 2013, 20(10): 102-105.
- [4] 冯煜,王梓楠.基于奇异值分解与神经网络的干扰识别[J].电子与信息学报,2020,42(11):2573-2578.
FENG M, WANG Z N. Interference recognition based on singular value decomposition and neural network[J]. Journal of Electronics & Information Technology, 2020, 42(11): 2573-2578.
- [5] 黄浩,吴利民,鲍蕾蕾,等.基于分形盒维数与小波包能量的干扰识别方法[J].空军预警学院学报,2014,28(6):422-426,435.
HUANG H, WU L M, BAO L L, et al. Jamming recognition scheme based on fractal box dimension and Wavelet packet energy[J]. Journal of Air Force Early Warning Academy, 2014, 28(6): 422-426, 435.
- [6] 方芳,李永贵,牛英滔,等.基于决策树模型的干扰信号识别[J].通信技术,2019,52(11):2617-2623.
FANG F, LI Y G, NIU Y T, et al. Interference signal identification based on decision tree algorithm[J]. Communication Technology, 2019, 52(11): 2617-2623.
- [7] 张自豪.基于支持向量机的地空通信干扰识别[D].成都:西华大学,2015.
ZHANG Z H. Ground and air communication interference identification based on support vector machine [D]. Chengdu: Xihua University, 2015.
- [8] 王鹏宇,程郁凡,徐昊,等.基于卷积神经网络联合多域特征提取的干扰识别算法[J].信号处理,2022,38(5):915-925.
WANG P Y, CHENG Y F, XU H, et al. Jamming classification using convolutional neural network-based joint multi-domain feature extraction[J]. Journal of Signal Processing, 2022, 38(5): 915-925.
- [9] 马键,张广晋,张磊,等.基于改进深度残差网络算法的智能干扰识别[J].电信科学,2022,38(10):98-106.
MA J, ZHANG G J, ZHANG L, et al. Improved ResNet algorithm based intelligent interference identification[J]. Telecommunications Science, 2022, 38(10): 98-106.
- [10] 魏迪,曾海彬,洪锋,等.基于 LSTM 网络和特征融合的通信干扰识别[J].电讯技术,2022,62(4):450-456.
WEI D, ZENG H B, HONG F, et al. Communication jamming signals recognition based on LSTM network and feature fusion[J]. Telecommunication Engineering, 2022, 62(4): 450-456.
- [11] 巩小雪,庞嘉豪,张琦涵,等.基于机器学习的光网络干扰攻击检测、

- 识别与恢复方法[J]. 通信学报, 2023, 44(7): 159-170.
- GONG X X, PANG J H, ZHANG Q H, et al. Machine learning-based detection, identification and restoration method of jamming attacks in optical networks[J]. Journal on Communications, 2023, 44(7): 159-170.
- [12] 王瑞东, 王世练, 张炜, 等. 基于自注意力机制的干扰信号检测识别[J]. 电讯技术, 2023, 63(6): 790-797.
- WANG R D, WANG S L, ZHANG W, et al. Self-attention-based jamming signals detection and classification[J]. Telecommunication Engineering, 2023, 63(6): 790-797.
- [13] 邵正途, 许登荣, 徐文利, 等. 基于 LSTM 和残差网络的雷达有源干扰识别[J]. 系统工程与电子技术, 2023, 45(2): 416-423.
- SHAO Z T, XU D R, XU W L, et al. Radar active jamming recognition based on LSTM and residual network[J]. Systems Engineering and Electronics, 2023, 45(2): 416-423.
- [14] WANG P Y, CHENG Y F, DONG B H, et al. Bring globality into convolutional neural networks for wireless interference classification[J]. IEEE Wireless Communications Letters, 2022, 11(3): 538-542.
- [15] FANG Z X, LUO Z Y, WANG X T. An efficient CNN-RNN recognition network for complex interference signal[C]//Proceedings of the 2022 Workshop on Electronics Communication Engineering. Bellingham: SPIE Press, 2023: 95-106.
- [16] WU L G, HU S L, XU J H, et al. Ship HRRP target recognition against decoy jamming based on CNN-BiLSTM-SE model[J]. IET Radar, Sonar & Navigation, 2024, 18(2): 361-378.
- [17] NGIAM J, KHOSLA A, KIM M, et al. Multimodal deep learning[C]//Proceedings of the 28th International Conference on International Conference on Machine Learning. New York: ACM Press, 2011: 689-696.
- [18] QI P H, ZHOU X Y, ZHENG S L, et al. Automatic modulation classification based on deep residual networks with multimodal information[J]. IEEE Transactions on Cognitive Communications and Networking, 2021, 7(1): 21-33.
- [19] ZHENG Q H, ZHAO P H, WANG H J, et al. Fine-grained modulation classification using multi-scale radio transformer with dual-channel representation[J]. IEEE Communications Letters, 2022, 26(6): 1298-1302.
- [20] WANG P Y, CHENG Y F, DONG B H, et al. Multi-domain networks for wireless interference recognition[J]. IEEE Transactions on Vehicular Technology, 2022, 71(6): 6534-6547.
- [21] DENG W, WANG X, HUANG Z T, et al. Modulation classifier: a few-shot learning semi-supervised method based on multimodal information and domain adversarial network[J]. IEEE Communications Letters, 2023, 27(2): 576-580.
- [22] LIU F G, PAN J Y, ZHOU R L. Contrastive learning-based multimodal fusion model for automatic modulation recognition[J]. IEEE Communications Letters, 2024, 28(1): 78-82.
- [23] ZHA Y P, WANG H J, SHEN Z X, et al. A few-shot modulation recognition method based on multi-modal feature fusion[J]. IEEE Transactions on Vehicular Technology, 2024, 73(7): 10823-10828.
- [24] ZHANG W N, XUE K L, YAO A Q, et al. Automatic modulation recognition based on multimodal information processing: a new approach and application[J]. Electronics, 2024, 13(22): 4568.
- [25] SHAO M Y, LI D Z, HONG S H, et al. IQFormer: a novel transformer-based model with multi-modality fusion for automatic modulation recognition[J]. IEEE Transactions on Cognitive Communications and Networking, 2025, 11(3): 1623-1634.
- [26] MEHR I E, DOVIS F. A deep neural network approach for classification of GNSS interference and jamming[J]. IEEE Transactions on Aerospace and Electronic Systems, 2025, 61(2): 1660-1676.
- [27] SWELDENS W. The lifting scheme: a construction of second generation wavelets[J]. SIAM Journal on Mathematical Analysis, 1998, 29(2): 511-546.
- [28] ZHANG J W, WANG T T, FENG Z X, et al. Toward the automatic modulation classification with adaptive wavelet network[J]. IEEE Transactions on Cognitive Communications and Networking, 2023, 9(3): 549-563.
- [29] QUAN Y H, CHENG N, WANG X C, et al. ALWNN: automatic modulation classification via adaptive lightweight wavelet neural network[C]//Proceedings of the 2024 IEEE Global Communications Conference. Piscataway: IEEE Press, 2024: 3835-3840.
- [30] QIN X Q, JIANG W H, GUI G, et al. Multilevel adaptive wavelet decomposition network-based automatic modulation recognition: exploiting time-frequency multiscale correlations[J]. IEEE Transactions on Cognitive Communications and Networking, 2025, 11(5): 3218-3231.

[作者简介]



杨渡佳 (1991-), 男, 安徽合肥人, 博士, 国防科技大学讲师, 主要研究方向为认知电子战、强化学习和群体智能等。

张欣然 (2002-), 男, 辽宁鞍山人, 国防科技大学硕士生, 主要研究方向为认知电子战、深度学习与模式识别等。

宋常建 (1981-), 男, 河南郑州人, 国防科技大学副教授, 主要研究方向为辐射源识别、认知电子战等。

王健 (1991-), 男, 安徽合肥人, 博士, 国防科技大学讲师, 主要研究方向为认知电子战、无人集群智能决策。

王伦文 (1966-), 男, 安徽休宁人, 博士, 国防科技大学教授、博士生导师, 主要研究方向为认知电子战、智能信息处理等。

朱然刚 (1979-), 男, 安徽萧县人, 国防科技大学博士生、副教授, 主要研究方向为抗干扰通信与无线通信网络。