

雷达有源电磁干扰视觉检测与参数估计方法

朱 轩^{1,2}, 阮江军¹, 吴 灏^{2*}, 史朝鹏^{2,3}, 何方敏², 孟 进²

(1. 武汉大学电气与自动化学院, 湖北武汉 430073; 2. 海军工程大学电磁能技术全国重点实验室, 湖北武汉 430033;
3. 华中科技大学电子信息与通信学院, 湖北武汉 430074)

摘要: 面向高动态变化、时频混叠、未知干扰等因素, 本文提出一种雷达有源电磁干扰视觉检测与参数估计方法, 旨在提升雷达系统电磁兼容性与抗干扰能力。首先, 基于电磁干扰信号建模仿真构建时频图像数据集, 并利用自适应对比度与边缘增强网络 (Adaptive Contrast and Edge Enhancement Network, ACEENet) 进行预处理, 强化边缘细节并抑制噪声; 然后, 利用所提降参增强网络 (Parameter Reduction Enhancement Network, PRENet), 嵌入三重注意力机制的 Slim-Neck (Slim-Neck with Triplet Attention Mechanism, Slim-Neck-TAM) 与组合损失函数改进 YOLOv8n 目标检测算法, 构建高精度电磁干扰视觉检测网络 (Electromagnetic Interference Visual Detection Network, EIVDNet), 实现干扰信号的模式识别与定位; 最终, 基于位置信息与参数估计原理实现干扰信号关键参数粗估计, 并通过 XGBoost 回归算法修正后获得精确估计值。实验结果表明, 所提方法电磁干扰信号检测精度与速度能够达到 99.30% 和 82.75 帧/秒, 且参数估计总误差为 1.01%, 在低信噪比/干噪比与未知干扰情况下依然具有良好的感知性能, 有助于提高雷达认知智能水平。

关键词: 雷达; 电磁干扰检测; YOLOv8; EIVDNet; 参数估计; XGBoost

基金项目: 国家自然科学基金 (No.62271497, No.61801502, No.52025072)

中图分类号: TN974

文献标识码: A

文章编号: 0372-2112(2025)04-1251-13

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20240875

Radar Active Electromagnetic Interference Visual Detection and Parameter Estimation Method

ZHU Xuan^{1,2}, RUAN Jiang-jun¹, WU Hao^{2*}, SHI Zhao-peng^{2,3}, HE Fang-min², MENG Jin²

(1. School of Electrical Engineering and Automation, Wuhan University, Wuhan, Hubei 430073, China;

2. National Key Laboratory of Electromagnetic Energy, Naval University of Engineering, Wuhan, Hubei 430033, China;

3. School of Electronic Information and Communications, Huazhong University of Science and Technology, Wuhan, Hubei 430074, China)

Abstract: Towards the factors such as high dynamic variation, time-frequency aliasing and unknown interference, this paper proposes a radar active electromagnetic interference visual detection and parameter estimation method, aiming to improve the electromagnetic compatibility and anti-jamming ability of the radar system. Firstly, the time-frequency image dataset is constructed based on the modelling and simulation of electromagnetic interference signals, and the adaptive contrast and edge enhancement network (ACEENet) is used for preprocessing to strengthen the edge details and suppress noise. Then, the proposed parameter reduction enhancement network (PRENet), slim-neck with triplet attention mechanism (Slim-Neck-TAM) and combined loss function are used to improve the YOLOv8n object detection algorithm, and a high-precision electromagnetic interference visual detection network (EIVDNet) is constructed to obtain the pattern and location of interference signals. Finally, based on the location information and parameter estimation principle, the rough estimation of the key parameters of the interference signal is realized, and the accurate estimation value is obtained after correction by the XGBoost regression algorithm. The results show that the detection precision and speed of the electromagnetic interference signal can reach 99.30% and 82.75 frames/s, and the overall error rate of parameter estimation is 1.01%, which has favourable perception performance under low signal-to-noise ratio / jamming-to-noise ratio and unknown interference and can be conducive to improve the level of radar cognitive intelligence.

Key words: radar; electromagnetic interference detection; YOLOv8; EIVDNet; parameter estimation; XGBoost

Foundation Item(s): National Natural Science Foundation of China (No.62271497, No.61801502, No.52025072)

1 引言

电磁干扰是影响现代电气与信息系统性能的重要因素,尤其是对于电磁频谱冲突日益严重的雷达系统平台.雷达作为电子对抗系统中不可或缺的装备之一,所处电磁环境日趋复杂,随时可能面临性能损失、设备损坏、位置暴露等问题^[1,2].雷达复杂电磁环境体系包含敌方(非合作方)恶意发送的强电磁干扰信号、己方电子通信设备辐射的杂散干扰、地物或云团等反射的多径干扰,呈现出空间宽广、能量不均、敏捷多变、时频混叠、信号密集等特点.因此,亟须开展复杂电磁环境下雷达电磁干扰信号感知方法研究,以提升雷达系统平台整体电磁兼容性与抗干扰能力.

目前,电磁干扰信号感知研究主要包括干扰模式感知与干扰参数感知两部分.对于干扰模式感知而言,采用假设检验^[3]和广义似然比^[4]等统计方法的干扰模式识别技术对观测信号存在过度拟合问题,以至于面向分布差异较大的复杂信号时应用效果显著降低.而基于特征提取的干扰识别技术,通常将电磁干扰信号转换至特定域^[5-7],然后经过降维、去噪、图像处理等方法提取多域变换空间内显著差异的知识特征,结合决策树^[8]、神经网络^[9]、支持向量机^[10]等分类算法,实现时序信号或变换图像上干扰类型的准确辨识^[11,12],但该类方法特征提取工程困难又繁琐,且抗噪声性能较弱.

得益于深度学习中卷积神经网络(Convolutional Neural Network, CNN)强大的特征表示能力,其已被众多学者应用于电磁干扰识别中,如文献[13]提出一种基于鲁棒功率谱的JRNet(Jamming Recognition Network)干扰识别网络,识别准确率达90%以上;文献[14]考虑电磁干扰信号实部与虚部的相关性,提出一种复数CNN模型;文献[15]设计出MLCNN(Multi-Label Convolutional Neural Network)网络模型,用于识别6种干扰调制方式任意组合下的雷达电磁干扰信号;文献[16]提出一种基于分数阶傅里叶变换(Fractional Fourier Transform, FrFT)的多特征融合网络,结合干扰信号分数域的局部与全局特征,在信噪比为-3 dB时准确率可达99%以上;文献[17]提出一种基于时频自注意和全局知识蒸馏的新型小样本干扰识别网络,能够在每类单一与复合干扰上达到98.50%的识别准确率.但以上方法在网络模型训练过程中需要定义干扰信号类型标签,而这也限制了标签的数量,导致模型只能识别预设复合干扰类型.随着复杂电磁环境下新型、未知干扰的引入,标签组合呈爆炸式增长,显著降低识别模型在实际应用场景中的鲁棒性与可靠性.

此外,干扰参数感知的准确性在很大程度上决定了波形优化设计、匹配滤波、干扰重建与消除等抗干扰方法的性能^[18],因此高精度干扰参数估计方法研究对

雷达系统稳定性尤为重要.文献[19]基于几何解析法与三角形思想进行参数粗估计,然后通过斜率逼近降低误差,仿真结果表明在信噪比(Signal-to-Noise Rate, SNR)大于0 dB时误差降到 10^{-2} ;文献[20]通过反脉冲分离机制确定时频图中宽带信号起点和终点,实现信号参数估计;文献[21]利用扩展Radon变换方法估计正弦调频信号的参数;文献[22]提出一种基于复数深度神经网络(Complex-Valued Deep Neural Network, CV-DNN)的参数估计处理器,实现了无先验信息条件下调制信号参数估计,尤其对Chrip信号的参数估计具有较强的鲁棒性.然而,现有电磁干扰信号参数感知方法还存在干扰模式单一、参数类型不全、性能较差等不足,且同样面临复杂电磁环境的威胁与挑战.

鉴于此,本文提出一种低参数数量与高精度的雷达有源电磁干扰视觉检测与参数估计方法,其主要贡献如下:(1)提出自适应对比度与边缘增强网络(Adaptive Contrast and Edge Enhancement Network, ACEENet),有效增强电磁干扰时频图对比度与边缘细节并抑制噪声;(2)提出一种电磁干扰视觉检测网络(Electromagnetic Interference Visual Detection Network, EIVDNet),实现单一干扰与混叠干扰的精准识别与定位;(3)基于参数估计原理与XGBoost回归算法,提出由粗到细的干扰信号精准参数估计方法.

2 电磁干扰信号模型与数据集

2.1 典型电磁干扰信号建模

为构建雷达有源电磁干扰信号视觉感知模型与参数估计网络所需数据集,根据数学模型对线性调频(Linear Frequency Modulation, LFM)有用信号、梳状谱干扰(Comb Spectrum Jamming, CSJ)、距离欺骗干扰(Distance Deception Jamming, DDJ)、密集假目标干扰(Dense False Target Jamming, DFTJ)^[23]、间歇采样转发干扰(Interrupted Sampling Repeater Jamming, ISRJ)^[24]和灵巧噪声干扰(Smart Noise Jamming, SNJ)^[25]进行仿真,其表达式为

$$\left\{ \begin{array}{l} S_{\text{LFM}}(t) = A \cdot \text{rect}\left(\frac{t}{T}\right) \exp\left[j2\pi\left(f_0 t + \frac{1}{2} k t^2\right)\right] \\ J_{\text{CSJ}}(t) = S_{\text{LFM}}(t) \sum_{i=1}^M a_i \exp(j2\pi f_i t) \\ J_{\text{DDJ}}(t) = A_J \cdot S_{\text{LFM}}(t - t_0 - \tau_0) \\ J_{\text{DFTJ}}(t) = \sum_{m=1}^{M_f} A_m \cdot S_{\text{LFM}}(t - t_0 - \tau_m) \\ J_{\text{ISRJ}}(t) = \sum_{p=1}^P \sum_{q=0}^{Q-1} \text{rect}\left(\frac{t - qT_\omega - pT_L}{T_L}\right) S_{\text{LFM}}(t - pT_L) \\ J_{\text{SNJ}}(t) = n(t) \cdot J_{\text{ISRJ}}(t) \end{array} \right. \quad (1)$$

式中, A 、 A_J 、 A_m 为对应信号幅度; a_i 为第 i 个频率点的幅

值; f_0, f_i 分别为中心频率和梳状频率; k 为调频斜率,即脉宽(T)与带宽(B)之比; τ_0, t_0 分别为干扰机转发时延和真实目标回波时延; τ_m 表示假目标转发间隔; M, M_f 为梳齿数和假目标数; P, Q 分别为转发次数和切片数; T_w, T_c 分别为采样间隔和切片宽度; $n(t)$ 为高斯白噪声; $\text{rect}(\cdot)$ 代表矩形脉冲函数,其定义为

$$\text{rect}\left(\frac{t}{T}\right) = \begin{cases} 1, & -\frac{T}{2} \leq t \leq \frac{T}{2} \\ 0, & \text{otherwise} \end{cases} \quad (2)$$

2.2 电磁干扰时频图像数据集

基于上述数学模型,结合表1所示各信号参数配置,仿真获得不同参数配置下 LFM 有用信号和干扰信号的时域波形,构建电磁干扰信号时域数据集 S_t ,其典型样本如图1(a)~图1(f)所示.其中,所有仿真信号的带宽(B)取值范围为5~10 MHz,且脉宽(T)取值范围为10~20 μs .在模型训练与测试中,干扰信号的SNR与干噪比(Jamming-to-Noise Rate, JNR)取值范围为20~60 dB;而在鲁棒性与泛化能力验证中,干扰信号的SNR与JNR取值范围则包含0~20 dB.

表1 典型有源电磁干扰信号仿真参数

信号类型	参数	设置值
LFM	时延	5~15 μs
CSJ	梳齿个数	6~10
	时延	10~20 μs
DDJ	时延	70~80 μs
DFTJ	转发间隔	{6, 8, 10, 12} μs
	假目标个数	3~5
ISRJ & SNJ	切片个数	1~4
	切片周期	{4, 8, 12, 16} μs
	占空比	50%

通过对 S_t 中每个信号样本进行短时傅里叶变换(Short-Time Fourier Transform, STFT)^[26],获得电磁干扰时频图像数据集 S_f .STFT 利用时间滑动窗口获得不同时间段的频率特性,解决干扰信号单一域(即时域或频域)特征信息不足的问题.其中,STFT 采用 Hamming 窗作为窗函数,分段数与傅里叶变换点数为128,重合点数为127.最终构建雷达有源电磁干扰时频图像数据集,样本总数为4 550,图像分辨率统一为 875×656 ,其典型样本如图1(g)~图1(l)所示.

此外,利用 LabelImg 按照 Pascal VOC 格式对 S_f 进行标签制作,即通过矩形框标注干扰信号的类别和位置,并自动生成相应的.xml标注文件,包含干扰类别(即 CSJ、LFM、DDJ、DFTJ、ISRJ、SNJ)与位置信息($x_{\min}, x_{\max}, y_{\min}, y_{\max}$).因此,若存在多干扰时频混叠,其能够实现独立和半开集识别效果.

2.3 自适应对比度与边缘增强网络

电磁干扰视觉检测网络预测框边界位置存在波动,导致后续参数估计误差大,因此提出基于限制对比度自适应直方图均衡(CLAHE)与 Laplacian 锐化的自适应对比度与边缘增强网络(Adaptive Contrast and Edge Enhancement Network, ACEENet),增强电磁干扰时频图像中目标信号与底噪之间的对比度和边缘细节,并抑制噪声影响.具体实现流程如下.

(1)将输入干扰信号的时频图像从 RGB 颜色空间转换到 Lab 颜色空间.

(2)将图像划分为若干互不重叠的小区域,并计算每个区域的直方图;每个直方图的灰度级为 r ,可能出现的灰度级为 w_r ,则每个小区域对应的直方图函数为 $h(r), 0 \leq r \leq w_r - 1$.

(3)对每个区域对应的直方图进行限制(裁剪),其具体原理为

$$h'(r) = \begin{cases} N_{\text{clip}} h(r) > N_{\text{clip}} - N_{\text{avg}} \\ h(r) + N_{\text{avg}} & h(r) \leq N_{\text{clip}} - N_{\text{avg}} \end{cases} \quad (3)$$

$$\begin{cases} N_{\text{clip}} = M_p / w_r' + T_c \cdot (M - M_p / w_r') \\ N_{\text{avg}} = \left(\sum_{r=0}^{w_r-1} \max\left[\left(h(r) - N_{\text{clip}}\right), 0\right] \right) / w_r' \end{cases} \quad (4)$$

式中, M_p 为各区域像素总数, T_c 为预先设置的限幅值, $h'(r)$ 为裁剪区域的直方图, N_{clip} 为实际阈值, N_{avg} 为重新分配到各直方图的平均像素值, w_r' 为各区域灰度级总数.

(4)重复步骤(2)~(3),直到所有被裁剪的像素被重新分配,然后使用双线性插值消除相邻区域边界像素不平滑的问题.

(5)将预处理的 L 通道与原始 a 和 b 通道叠加,重构转换至 RGB 颜色空间,以获得 CLAHE 预处理时频图像,最后通过 Laplacian 锐化进行电磁干扰信号边缘细节强化,其效果如图1(m)~图1(r)所示.

3 雷达有源电磁干扰感知模型

为满足低SNR或JNR、多干扰混叠、新型未知干扰情况下雷达有源电磁干扰的低复杂度与高精度实时感知,本文提出基于 EIVDNet 与参数估计网络的干扰感知方法,其大致实现框架如图2所示.下面将详细介绍其实现原理.

3.1 电磁干扰视觉检测网络

电磁干扰视觉检测网络(EIVDNet)的构建思路主要是以 YOLOv8n 轻量化目标检测算法为基准,以降低模型参数量与计算量为主旨,设计新型低复杂度特征提取与处理模块,在降低模型推理算力需求的同时实现检测精度的提升.其结构如图3所示,主要包括降参增强网络(PRENet)、Slim-Neck-TAM 特征融合网络与组合损失函数3个部分的改进.

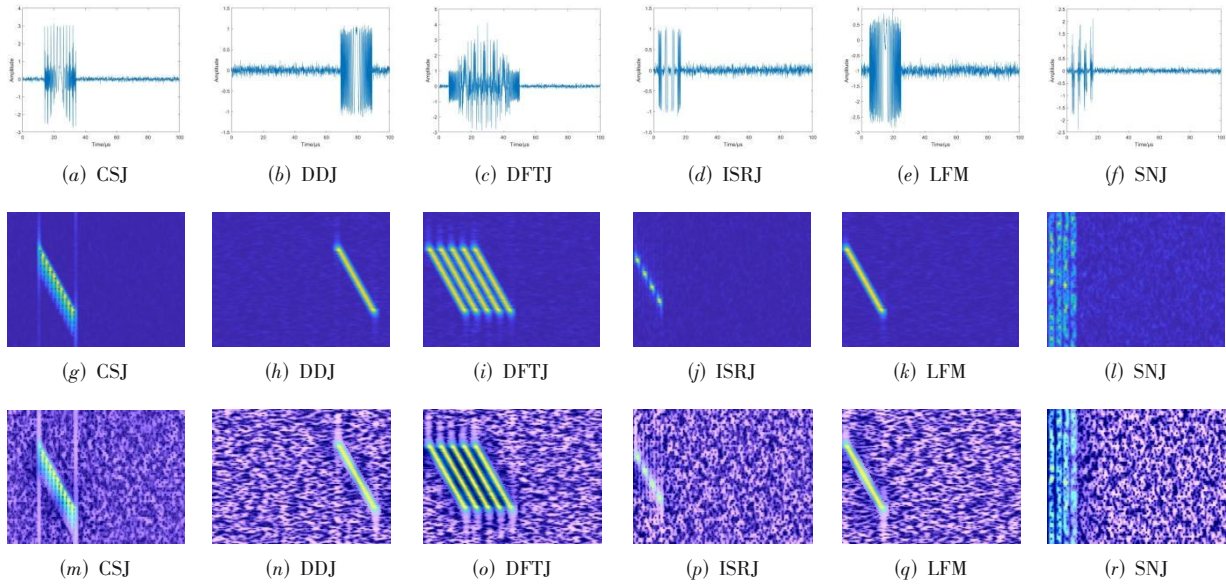


图1 电磁干扰时频图像数据集典型样本

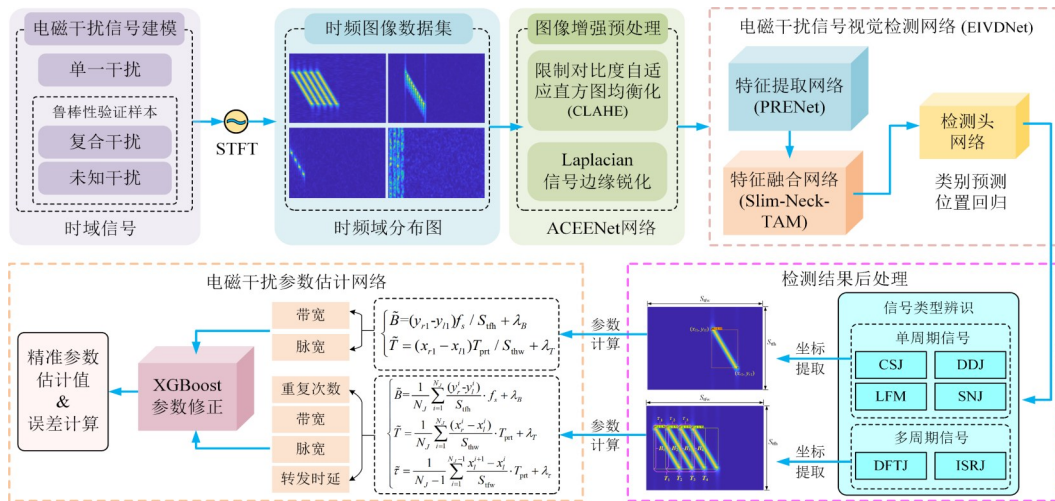


图2 电磁干扰视觉检测与参数估计实现原理框架

3.1.1 降参增强网络

降参增强网络(PRENet)是结合所提创新设计的C2fLC模块与SimSPPFCSPC空间金字塔池化模块改进YOLOv8n特征提取网络(Backbone)而来,具体为引入轻量级且高性能LightConv(LConv)^[27]卷积改进原始C2f模块,再以SimSPPFCSPC替代SPPF空间金字塔池化模块。

LConv由 1×1 Conv层(Convolution Layer)、BN层(Batch Normalization)和 3×3 DWConv层(Depthwise Convolution)构成。其中, 1×1 卷积可对输入特征进行线性组合与压缩;BN层能够防止梯度消失且加速模型收敛;而DWConv打破输入与输出通道连接,减少模型参数量。假设输入特征维度为 $D \times D \times C_{in}$,输出为 $D \times D \times C_{out}$,则LConv与普通卷积、深度可分离卷积(Depthwise Separable Convolution, DSConv)的参数量差异如

图4和式(5)所示。

$$\begin{cases} P_{\text{Conv}} = C_{in} \times C_{out} \times k \times k \\ P_{\text{DSConv}} = C_{in} \times k \times k + C_{in} \times C_{out} \\ P_{\text{LConv}} = C_{in} \times (C_{in}/\beta) + (C_{in}/\beta) \times k \times k \times C_{out} \end{cases} \quad (5)$$

式中, k 为卷积核大小, β 为LConv中 1×1 卷积的通道缩放比例。大多数C2fLC模块中 $C_{in} = C_{out}$,因此LConv卷积能够将参数量降低至普通卷积的 $1/(\beta k^2) + 1/\beta$ 倍。

此外,为了在控制参数量增长情况下最大程度地提高模型检测精度,提出一种具有高性价比的SimSPPFCSPC模块,其伪代码结构如算法1所示。保留类似YOLOv7^[28]中SPPFCSPC的CBS $\times 3$ 和CBS $\times 2$ 模块结构,提高模型对多干扰混叠情况下特征处理能力,但同时也增加了参数量。因此,为平衡模型参数量和检测实时性,参考SimSPPF^[29]设计引入SimConv卷积层,结合BN

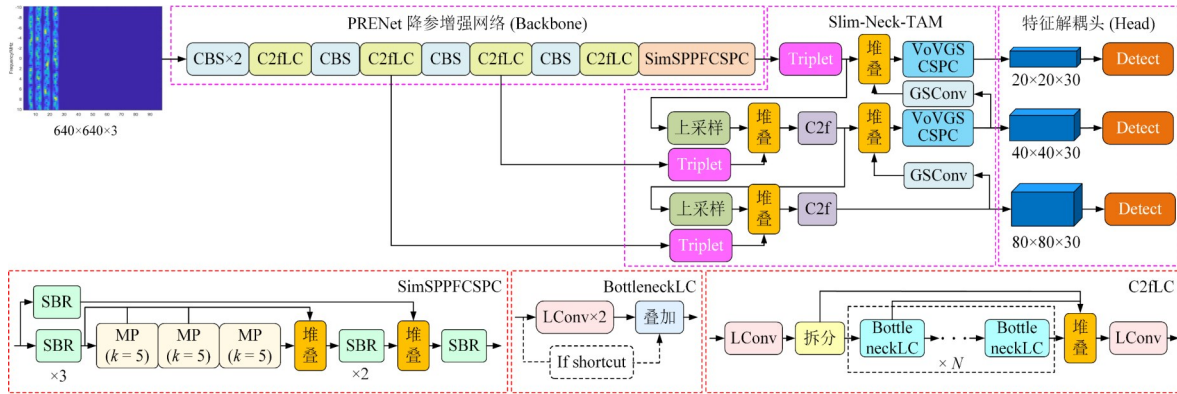


图3 EIVDNet电磁干扰视觉检测网络结构

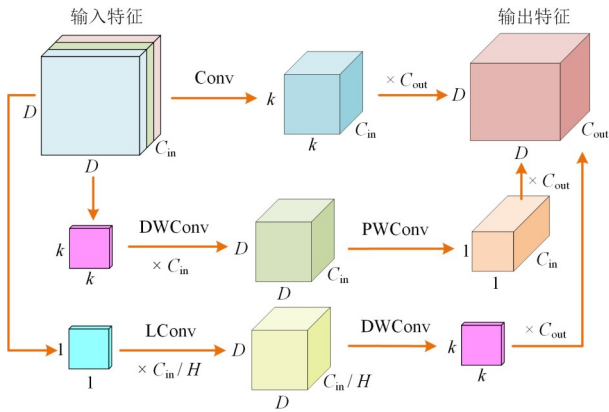


图4 LConv参数数量对比

层与 ReLU 激活函数构建 SBR 卷积模块,并在 SimConv 中进一步引入分组卷积(Group Convolution, GConv)思想,进一步缩减该结构模块的参数数量,最终设计出 SimSPPFCSPC 空间金字塔池化模块,在检测精度与推理效率上具有良好的平衡性。

3.1.2 Slim-Neck-TAM

原始 YOLOv8 中 PAFPN 特征融合网络采用大量普通卷积提取特征,使得模型复杂度高且检测速度低,因此本文基于 Slim-Neck 结构范式与 Triplet 注意力机制构建出嵌入三重注意力机制的 Slim-Neck 特征融合网络(Slim-Neck with Triplet Attention Mechanism, Slim-Neck-TAM)。原始 Slim-Neck 由广义稀疏卷积(Generalized-Sparse Convolution, GSCConv)^[30]设计的块 GSbottleneck 和 VoVGS C2f 轻量化模块构成,其能够利用 shuffle 操作实现跨阶段空间与通道特征融合,提高上下文语义特征利用率并加速网络预测,如图 5 所示。

由于原始 Slim-Neck 结构范式中的 VoVGS C2f 采用普通卷积提取特征,所以考虑检测精度与速度的平衡,提出一种更加轻量化的 VoVGS C2f 模块,即将 GSbottleneck 结构中的普通卷积分支替换为深度可分离卷积(DWConv),能够在轻量化的同时提升对空间特征信息的提取与利用。

算法 1 SimSPPFCSPC 模块

输入: 电磁干扰信号时频图像特征向量

1. 定义 SimConv 模块:
2. 卷积: Conv2d ($C_{in}, C_{out}, k, s, g, bias=False$)
3. 批量正则化: BatchNorm2d ($C_{out}, eps, momentum$)
4. 激活函数: ReLU ($x, inplace=True$)
5. 返回值: ReLU (BatchNorm2d(Conv2d(x)))
6. 定义 SimSPPFCSPC 模块:
7. cv1: SimConv ($c_1, c, 1, 1, g$)
8. cv2: SimConv ($c, c, 3, 1, g$)
9. cv3: SimConv ($c, c, 1, 1, g$)
10. 最大值池化: MaxPool2d (kernel_size, s, p)
11. cv4: SimConv ($4*c, c, 1, 1, g$)
12. cv5: SimConv ($2*c, c_2, 1, 1, g$)
13. 前向运算过程:
14. $x_1 = cv3(cv2(cv1(input)))$
15. $x_2 = MaxPool2d(x_1)$
16. $x_3 = MaxPool2d(x_2)$
17. $y_1 = cv2(cv4(cat((x_1, x_2, x_3, MaxPool2d(x_3)), 1)))$
18. $y_2 = cv1(input)$
19. 返回值: cv5(cat((y_1, y_2), dim=1))
20. 参数配置:
21. kernel_size=5, s=1, g=4, p=2, $\alpha=0.1$, eps=0.01

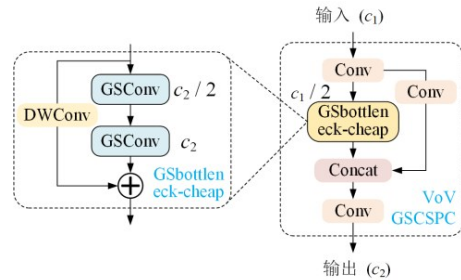


图5 Slim-Neck结构范式

鉴于低 SNR 或 JNR 条件下噪声对电磁干扰信号的抑制效果,有用信号和干扰信号的特征越来越不显著,

且噪声的冗余特性易致使模型失效. 所以进一步在 Slim-Neck 中嵌入 Triplet 注意力机制^[31], 增强关键特征的提取和筛选, 提高模型的抗噪声能力, 其结构如图 6 所示, 主要由 3 个平行分支组成. 假设给定的输入特征 $\mathbf{Z} \in \mathbb{R}^{C \times H \times W}$, 其为 3 个分支中的每个分支的输入特征. 在第 1 个分支中, 构建高度 (H) 和通道 (C) 维度之间的交互. 首先, 输入特征 \mathbf{Z} 需要沿 H 轴逆时针旋转 90° , 旋

转后的特征 $\hat{\mathbf{Z}}_1 \in \mathbb{R}^{W \times C \times H}$ 通过式 (6) 进行 Z-Pool 层处理, 得到 $\hat{\mathbf{Z}}_1^* \in \mathbb{R}^{2 \times H \times C}$. 然后, 通过核大小为 7×7 的 Conv 层和 BN 层将 $\hat{\mathbf{Z}}_1^*$ 归一化为 $1 \times H \times C$, 并通过 Sigmoid 函数获得注意力权重. 最后, 生成的注意力权重再与 $\hat{\mathbf{Z}}_1$ 进行像素级相乘, 最后沿 H 轴顺时针旋转 90° 后输出与 \mathbf{Z} 大小相同的精细化特征.

$$\mathbf{Z}\text{-Pool}(\chi) = [\text{MaxPool}_C(\chi), \text{AvgPool}_C(\chi)] \quad (6)$$

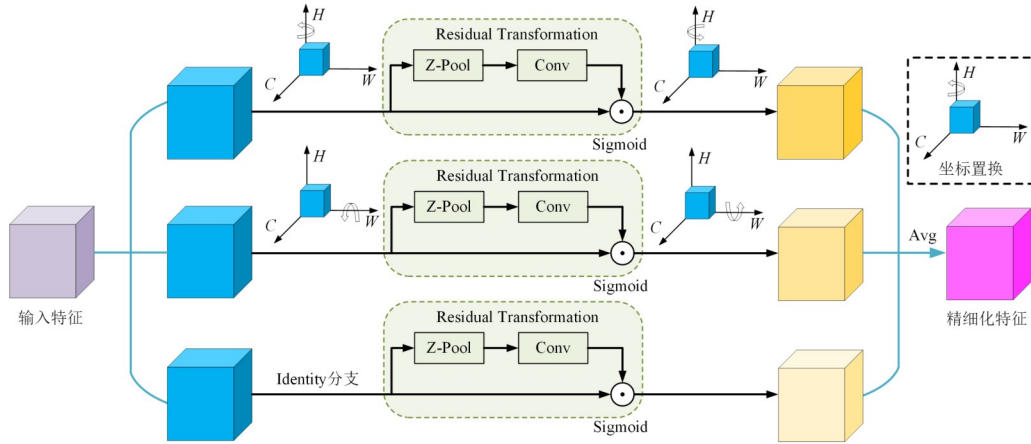


图6 Triplet注意力机制结构原理

式中, $\text{MaxPool}_C(\chi)$ 和 $\text{AvgPool}_C(\chi)$ 分别表示对输入特征 χ 所在通道进行最大值池化和平均值池化.

同理, 按照类似结构可获得其他分支的精细化特征, 最终 Triplet 注意力机制输出可以表示为

$$y = \frac{1}{3} \left[\hat{\mathbf{Z}}_1 \sigma(f_1(\hat{\mathbf{Z}}_1^*)) + \hat{\mathbf{Z}}_2 \sigma(f_2(\hat{\mathbf{Z}}_2^*)) + \mathbf{Z} \sigma(f_3(\hat{\mathbf{Z}}_3)) \right] \quad (7)$$

式中, σ 为 Sigmoid 激活函数; f_1, f_2, f_3 分别表示 Triplet 注意力机制的 3 个分支中核大小为 7×7 的卷积操作. 简化后 y 可表示为

$$y = \frac{1}{3} \left(\hat{\mathbf{Z}}_1 q_1 + \hat{\mathbf{Z}}_2 q_2 + \mathbf{Z} q_3 \right) = \frac{1}{3} (\bar{y}_1 + \bar{y}_2 + y_3) \quad (8)$$

式中, q_1, q_2, q_3 分别为 Triplet 注意力机制的 3 个跨维度注意力权重, \bar{y}_1 和 \bar{y}_2 表示 90° 顺时针旋转以保持 $C \times H \times W$ 的原始输入尺寸.

3.1.3 组合损失函数

考虑到电磁干扰信号在时频图上形状差异明显, 尺寸大小变化大, 且边框回归精度直接影响后续参数估计性能. YOLOv8 中采用的 CIoU 损失函数对宽高比定义较为模糊, 导致边框回归时边界具有随机性, 因此本文提出以 SIoU^[32] 为边框回归损失, 并在模型训练时结合 EIoU^[33] 损失函数决策正负样本动态分配.

EIoU 包括距离损失、IoU 损失和宽高损失 3 个部分, 通过最小化预测框与精细化标注真实框宽、高之间的差异, 从而获得更加精准的边界框. 其计算原理表达式为

$$\begin{aligned} L_{\text{EIoU}} &= L_{\text{IoU}} + L_{\text{dis}} + L_{\text{asp}} \\ &= 1 - \text{IoU} + \frac{\rho^2(B, B^{\text{gt}})}{(w^c)^2 + (h^c)^2} + \frac{\rho^2(w, w^{\text{gt}})}{(w^c)^2} + \frac{\rho^2(h, h^{\text{gt}})}{(h^c)^2} \end{aligned} \quad (9)$$

式中, h^c 和 w^c 分别为最小包围框的高和宽, w 和 w^{gt} 分别为预测框 (B) 与真实框 (B^{gt}) 的宽, h 和 h^{gt} 分别为预测框与真实框的高, $\rho^2(\cdot)$ 为欧式距离函数.

SIoU 损失函数在距离损失与形状损失之外, 还考虑到期望回归向量之间的角度, 额外定义并增加了角度损失, 加速预测框收敛并改进了整体形状收敛效果. 其表达式为

$$L_{\text{SIoU}} = 1 - \text{IoU} + \frac{\Delta + \Omega}{2} \quad (10)$$

式中, IoU 为预测框与真实框的交并比, Δ 为考虑角度损失的距离损失, Ω 为形状损失. 其定义为

$$\begin{cases} \Delta = \sum_{t=x,y} (1 - e^{-\gamma t}) \\ \Omega = \sum_{t=w,h} (1 - e^{-w_t})^\theta \\ \rho_x = \left(\frac{B_{c_x}^{\text{gt}} - B_{c_x}}{c_w} \right), \rho_y = \left(\frac{B_{c_y}^{\text{gt}} - B_{c_y}}{c_h} \right), \gamma = 2 - A \\ \omega_w = \left| \frac{w - w^{\text{gt}}}{\max(w, w^{\text{gt}})} \right|, \omega_h = \left| \frac{h - h^{\text{gt}}}{\max(h, h^{\text{gt}})} \right| \end{cases} \quad (11)$$

式中, θ 为形状权重因子, 即模型对形状的关注程度, 默认设置为 4^[32]; 而 A 为角度损失, 其计算原理与表达式

如图 7 和式 (12) 所示.




图 7 SLoU 损失函数计算原理

$$\begin{cases} A = 1 - 2 \cdot \sin^2(\arcsin(x) - \pi/4) \\ x = c_h / \sigma = \sin(\alpha) \\ \sigma = \sqrt{(B_{c_x}^{gt} - B_{c_x})^2 + (B_{c_y}^{gt} - B_{c_y})^2} \\ c_h = \max(B_{c_x}^{gt}, B_{c_x}) - \min(B_{c_x}^{gt}, B_{c_x}) \end{cases} \quad (12)$$

3.2 电磁干扰参数估计网络

3.2.1 参数估计原理

根据电磁干扰信号的脉冲重复次数,可以将参数估计分为两大类,即单周期与多周期.单周期信号类型包括 LFM、CSJ、DDJ 和 SNJ,多周期信号类型包括 DFTJ 和 ISRJ.单周期信号参数包括带宽 B 和持续时间 T (即脉宽),而多周期信号参数除带宽与脉宽外,还包括定量参数 (如重复次数 N) 和周期性参数 (转发间隔 τ).参数估计原理如图 8 所示.

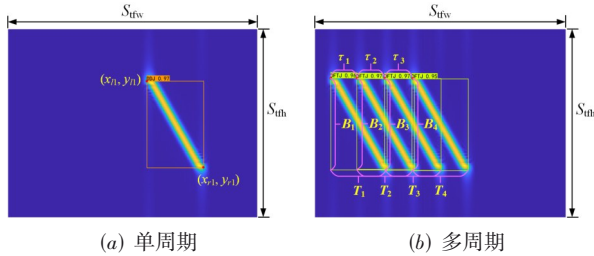


图 8 参数估计原理示意图

(1) 单周期信号参数估计

根据干扰信号时频分布图像,纵轴为采样频率 (f_s),横轴为脉冲重复周期 (T_{prt}),如图 8(a) 所示.结合图像宽度和高分辨率 $S_{thw} \times S_{th}$,可以计算出信号的估计带宽 (\tilde{E}_B) 和脉冲宽度 (\tilde{E}_T) 为

$$\begin{cases} \tilde{E}_B = (y_{r1} - y_{l1}) f_s / S_{th} \\ \tilde{E}_T = (x_{r1} - x_{l1}) T_{prt} / S_{thw} \end{cases} \quad (13)$$

(2) 多周期信号参数估计

对于定量参数而言,可通过统计方法直接得到的多周期干扰信号转发次数 (N).而对于周期性参数,可通过每个周期计算结果的平均值来反映,如图 8(b) 所示,具体为

$$\begin{cases} \tilde{E}_B = \frac{1}{N_J} \sum_{i=1}^{N_J} \frac{(y_r^i - y_l^i)}{S_{th}} \cdot f_s \\ \tilde{E}_T = \frac{1}{N_J} \sum_{i=1}^{N_J} \frac{(x_r^i - x_l^i)}{S_{thw}} \cdot T_{prt} \\ \tilde{E}_\tau = \frac{1}{N_J - 1} \sum_{i=1}^{N_J - 1} \frac{x_l^{i+1} - x_l^i}{S_{thw}} \cdot T_{prt} \end{cases} \quad (14)$$

式中, N_J 为多周期干扰重复次数, \tilde{E}_B 、 \tilde{E}_T 、 \tilde{E}_τ 分别为带宽、脉宽、转发间隔的估计值, (x_l, y_l, x_r, y_r) 为检测框左上顶点和右下顶点的像素坐标.

3.2.2 XGBoost 参数修正

根据参数估计原理对电磁干扰视觉检测结果进行后处理便可获得粗略估计值,但由于没有算法可以达到 100% 的准确率,且边框位置始终存在随机扰动,因此提出基于 XGBoost (Extreme Gradient Boosting)^[34] 回归预测算法的参数估计修正方法.

XGBoost 是基于多个梯度提升树的集成学习方法,凭借其非线性拟合能力强、训练速度快、异常值鲁棒性好等优点,被广泛用于回归预测与参数估计中.对于 $n \times m$ 维数据,其数学模型可以表示为

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i), \quad f_k \in F (i=1, 2, \dots, n) \quad (15)$$

式中, f_k 为第 k 棵决策树的预测结果, K 为所有回归树的集合, x_i 为第 i 个样本, F 包含所有可能的决策树模型.在模型训练时,需通过最小化目标函数以寻找最优参数,其目标函数 L 为

$$\begin{cases} L = \sum_i l(\hat{y}_i - y_i) + \sum_k \Omega(f_s) \\ \Omega(f) = \gamma T + \frac{1}{2} \lambda \|w\|^2 \end{cases} \quad (16)$$

式中, l 为预测值与实际值之间的误差损失, Ω 为正则化函数, T 为叶子节点数, w 为叶子节点的权重值, λ 与 γ 为自定义参数, γT 与 $\lambda \|w\|^2$ 分别为 L1 正则化和 L2 正则化的惩罚项.

4 实验与结果分析

4.1 实验配置与性能指标

实验环境配置包含 Windows 10、Intel (R) Core (TM) i5-11400H、RAM 16 G、NVIDIA GeForce RTX 3060 GPU 等硬件环境,以及 PyTorch 1.7.1、Python 3.7、Visual Studio Code 2023 等软件环境.

为便于分析改进方法效果及不同检测算法性能,引入平均精度 (Average Precision, AP)、平均精度均值 (mean Average Precision, mAP) 与平均 F1 分数 (mean F1 score, mF1)^[35] 来描述视觉检测模型的检测精度;并且采用每秒检测图像数 (Frames Per Second, FPS)、浮点运算量 (FLOPs) 与参数量 (Params) 等评价指标来分别衡

量模型的检测速度、计算复杂度和大小。

电磁干扰信号视觉检测模型(EIVDNet)训练与测试过程中参数设置如表2所示. 其中,输入电磁干扰时频图像样本会按照9:1的比例划分为训练集(含验证集)与测试集,并通过冻结/解冻两阶段训练策略与随机Mosaic数据增强方法获得最优EIVDNet模型,训练过程损失曲线如图9所示. 对于参数估计网络性能评价,则采用平均误差(E_{avg})、平均误差均值(E_{mAE})与总误差(E_{err})分别描述单类信号各参数估计性能与总估计性能,其计算表达式如下:

$$\begin{cases} E_{\text{avg}} = \frac{1}{N_T} \sum_{i=1}^{N_T} |(y'_i - y_i)| / y_i \times 100\% \\ E_{\text{mAE}} = \frac{1}{N_p} \sum_{i=1}^{N_p} E_{\text{avg}}^i \times 100\% \\ E_{\text{err}} = \frac{1}{N_s} \sum_{i=1}^{N_s} E_{\text{mAE}}^i \times 100\% \end{cases} \quad (17)$$

式中, y' 、 y 分别为估计值和真实值, N_T 、 N_p 分别为每类信号的时频图像测试样本总数和估计参数类型总数, N_s 表示信号类型总数.

4.2 消融实验

为验证降参增强网络PRENet、Slim-Neck-TAM结构范式与SiIoU-EIoU组合损失函数改进方法的有效性,开展如表3所示消融实验,其中,"√"表示采用对应改进方法.

根据表3结果可知,在原始YOLOv8n的基础之上,引入降参增强网络PRENet作为新的特征提取网络,能够提升0.3个百分点的检测精度(mAP),且计算量(FLOPs)与参数量(Params)缩减 9.6×10^8 和 1.4×10^5 . 而当在特征融合网络中引入基于VoVGSCSPC模块设计

表3 不同改进方法的消融实验结果

实验组别	降参增强网络PRENet	Slim-Neck-TAM		组合损失函数SiIoU+EIoU	mAP/%	FPS/(帧/秒)	FLOPs/ 10^9	Params/ 10^6
		Slim-Neck	Triplet注意力机制					
1					98.03	70.22	8.20	3.01
2	√				98.33	79.62	7.26	2.87
3	√	√			98.55	82.96	6.69	2.43
4	√	√	√		98.88	81.61	6.69	2.43
5	√	√	√	√	99.30	82.75	6.69	2.43

4.3 不同检测算法性能对比

为验证所提EIVDNet电磁干扰视觉检测模型的性能,额外构建Faster RCNN^[36]、YOLOv5s^[37]、YOLOv7x^[28]、YOLOX-nano^[38]、YOLOX-tiny^[39]等主流检测算法模型,在同一数据集样本和训练参数配置下,结合AP、mAP、FPS、mF1、FLOPs、Params等指标综合评价以上检测算法,其结果如表4所示.

根据表4结果可知,Faster RCNN与YOLOv5s检测

表2 模型训练参数配置

参数名称	第1阶段	第2阶段
批大小(Batchsize)	8	4
训练轮次(Epoch)	50	50
初始学习率	1×10^{-2}	
最小学习率	1×10^{-4}	
优化器	SGD	
动量(Momentum)	0.937	
Mosaic数据增强概率	0.5	
Mosaic数据增强作用轮次	70	




图9 模型训练与验证损失曲线

的Slim-Neck结构范式后,更进一步实现了计算量与参数量的降低;在引入无参Triplet注意力机制与组合损失函数改进方式后,在保持低运算量与参数量情况下,进一步将mAP提升至99.30%,同时将计算量与参数量降低18.41%与19.27%. 综上所述,所提模型具备高精度且较低复杂度的电磁干扰感知性能.

精度(mAP)最差,分别为91.91%和93.88%,而其他模型的mAP均高于96%. 通过使用更深层网络结构的YOLOv7x和YOLOv8x^[35]可以提取干扰信号与背景之间的显著差异性特征,更好地捕获物理特征和关联信息,使得其mAP分别达98.83%与99.64%. 同时其mF1分数分别为0.97、0.98,即两者均具有良好的查准率和查全率. 但由于参数量(Params)和浮点运算量(FLOPs)较大,YOLOv7x与YOLOv8x的FPS分别为

表 4 不同视觉检测算法的结果对比

检测算法	各类信号检测精度 AP /%						mAP/%	FPS/ (帧/秒)	mF1 分数	FLOPs/10 ⁹	Params/10 ⁶
	LFM	CSJ	DDJ	DFTJ	ISRJ	SNJ					
Faster RCNN	100	100	100	91.32	62.87	97.27	91.91	10.10	0.89	369.84	136.79
YOLOv5s	90.43	100	87.65	93.50	94.65	97.07	93.88	61.96	0.63	16.52	7.08
YOLOv7-tiny	100	100	100	95.65	86.40	99.47	96.92	68.32	0.88	13.22	6.03
YOLOX-tiny	100	100	100	87.57	100	100	97.93	54.81	0.98	15.24	5.03
YOLOv8n	100	100	100	88.08	100	100	98.03	70.22	0.97	8.20	3.01
YOLOv7x	100	100	100	91.02	99.91	99.36	98.38	17.26	0.97	188.99	70.85
YOLOv8x	100	100	100	97.84	100	100	99.64	15.94	0.99	258.15	68.16
EIVDNet	100	100	100	96.76	100	99.05	99.30	82.75	0.98	6.69	2.43

17.26 帧/秒、15.94 帧/秒,显然不利于模型部署与实时性需求。

从 YOLOv7-tiny、YOLOX-tiny、YOLOv8n 等轻量化视觉检测模型结果对比来看,YOLOv8n 在特征提取过程中利用乘数因子控制特征图原始通道大小,大大降低了计算复杂度,因此其 mAP 与 FPS 分别能够达到 98.03% 与 70.22 帧/秒。相比之下,本文所提 EIVDNet 模型能够将检测精度提升至 99.30%,同时获得 82.75 帧/秒的检测速度,具备类似 YOLOv8x 大模型的检测精度,且在有限资源条件下降低了硬件性能要求、加快了推理运算。

4.4 参数估计性能分析

通过仿真额外获得不同带宽、脉宽、转发间隔、SNR 或 JNR 情况下时频图样本,其中包括 CSJ、DDJ、DFTJ、LFM 信号各 300 张,ISRJ 和 SNJ 干扰信号分别有 400 张和 450 张,共计 2 050 张,利用 EIVDNet 进行检测,结合基于参数估计原理计算获得的粗估计值与实际值,构建 XGBoost 修正算法训练样本集,从而拟合粗估计值与实际值之间的映射关系。此外,为验证 ACEENet 预处理方法的有效性,采用每类信号 120 张时频图像样本进行测试,根据预处理前后参数估计差值(即估计值-实际值)绘制如图 10 所示的箱线图,并在此基础上,利用 XGBoost 回归算法对估计值进行修正,统计修正前后每类信号关键参数的估计误差(E_{avg} 、 E_{MAE})与总估计误差(E_{err}),具体结果如表 5 所示。

根据图 10 结果可知,当以预处理增强后的时频图作为输入时,带宽、脉宽、转发间隔的估计值与实际值之间分布差异更小,但难以满足异常值与更加精准的参数估计要求。根据表 5 结果可知,当采用基于参数估计原理的直接估计方法时,所有类型信号参数估计总误差(E_{err})为 9.83%,且 CSJ 信号的带宽估计误差为 42.07%,其主要原因是边缘区域能量分布发散与不确定性导致边框回归波动范围大。而通过 XGBoost 回归算法进行修正后,CSJ 信号的平均误差均值(E_{MAE})降低至 3.28%,其带宽估计误差缩减至 5.97%,而且其他各类干扰信号的估计误差 E_{MAE} 均小于 1%。总体而言,凭

借 XGBoost 非线性拟合能力强与异常值鲁棒性好的优点,能够将总误差(E_{err})降低至 1.01%,验证了所提方法能够对参数估计结果进行精准修正,以满足雷达系统抗干扰算法及策略选择对先验信息的需求。

4.5 鲁棒性与泛化能力验证

(1) 低 SNR 或 JNR 影响分析

为验证所提方法面向实际工程应用中的鲁棒性与泛化能力,额外利用低 SNR 或 JNR 情况(即 0~20 dB 范围)下不同干扰信号时频图像样本进行检验,各信号类型样本数量均为 100 张,共计 600 张。所提方法性能随 SNR 或 JNR 变化的结果曲线如图 11 所示,包括 EIVDNet 检测精度性能与参数估计性能。

根据图 11(a)可知,CSJ、DDJ、LFM 的检测精度在 SNR 或 JNR ∈ [0, 20] dB 范围内均为 100%;DFTJ、ISRJ、SNJ 的检测精度随 SNR 或 JNR 的降低而显著下降,且当 SNR 或 JNR 为 0 dB 时,其检测精度均小于 90%。总体而言,EIVDNet 电磁干扰视觉检测模型的检测精度在 SNR 或 JNR ≥ 0 dB 时,检测精度可达 93% 以上,表明 EIVDNet 模型在低 SNR 或 JNR 下依然具有良好的检测精度与泛化性。

对于参数估计性能而言,从图 11(b)结果可知,各类干扰信号参数估计误差均随 SNR 或 JNR 降低而增大,尽管 EIVDNet 模型能够准确检测出信号类型,但噪声功率的增大导致信号边缘模糊,边框回归时位置预测波动范围明显增大,从而使得估计参数时误差增大。其中,DFTJ 与 ISRJ 参数估计误差主要来源于假目标个数与转发切片数的漏检,而 SNJ 参数估计误差则主要来源于噪声功率增大的抑制效果。但总体而言,凭借 EIVDNet 模型高精度检测性能与 XGBoost 回归修正,在 SNR 或 JNR ≤ 5 dB 时参数估计总误差控制在 5% 以内,且在 SNR 或 JNR = 0 dB 时总估计误差为 8.28%。结果表明,所提方法能够在低信噪比或干噪比下保持高精度检测与精准参数估计性能,具有良好的鲁棒性与泛化能力。

(2) 未知/混叠干扰影响分析

考虑实际雷达系统应用场景的复杂性,不可避免

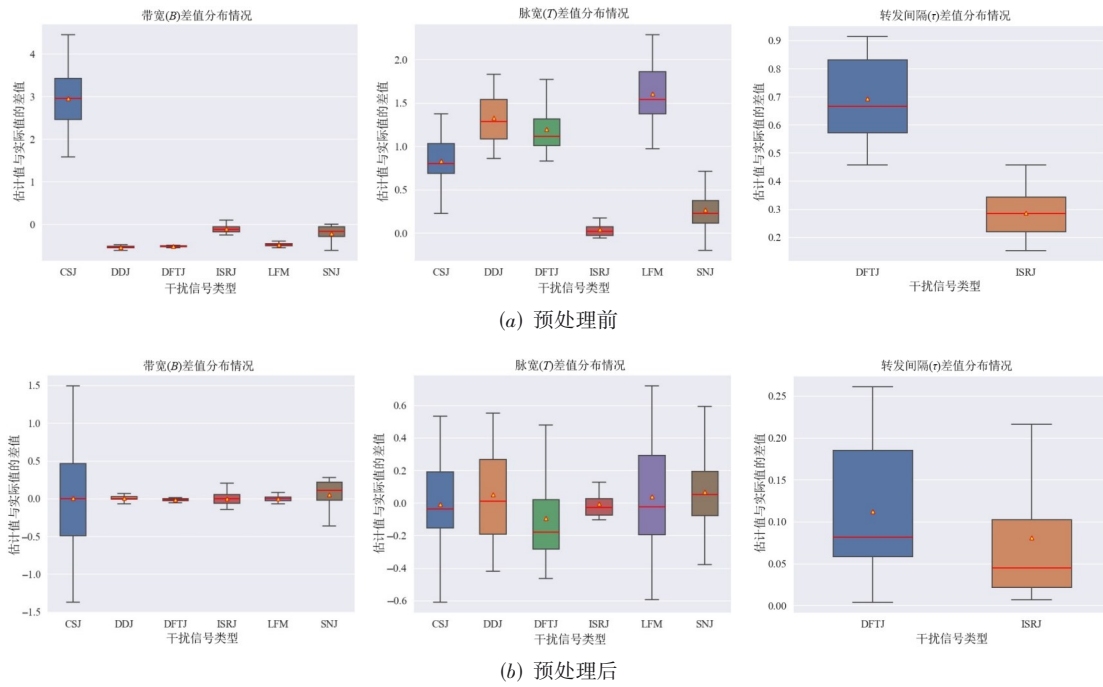


图 10 ACEENet 预处理前后参数估计差值分布情况

表 5 XGBoost 回归修正前后参数估计误差结果对比

信号类型	修正前-平均误差 $E_{\text{avg}} / \%$			平均误差均值 $E_{\text{mAE}} / \%$	修正后-平均误差 $E_{\text{avg}} / \%$			平均误差均值 $E_{\text{mAE}} / \%$	
	带宽 (B)	脉宽 (T)	转发间隔 (τ)		带宽 (B)	脉宽 (T)	转发间隔 (τ)		
CSJ	42.07	5.58	—	23.83	5.97	0.59	—	3.28	
DDJ	7.53	8.98	—	8.26	0.41	0.43	—	0.42	
DFTJ	7.86	8.71	6.75	7.77	0.57	0.59	0.40	0.52	
ISRJ	7.06	1.97	11.78	6.94	0.48	0.56	0.60	0.55	
LFM	6.50	10.44	—	8.47	0.59	0.63	—	0.61	
SNJ	1.08	6.37	—	3.73	0.25	1.10	—	0.68	
总估计误差 (E_{err})				9.83	总估计误差 (E_{err})				1.01

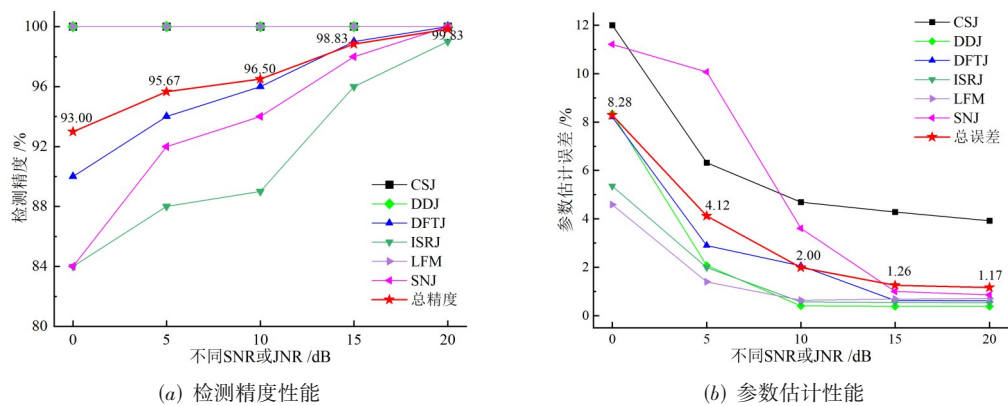


图 11 低 SNR 或 JNR 下性能分析结果

地遭受未知、新型、混叠干扰的影响,极大地降低模型检测性能与可靠性. 为此,本文以噪声调频干扰(Noise Frequency Modulation Jamming, NFMJ)为未知干扰,仿

真获得多干扰混叠与未知干扰引入情况下各 100 个待测样本,输入至 EIVDNet 网络模型中进行检测,其统计结果与典型示例如表 6 和图 12 所示.

根据表 6 结果可知, NFMJ 噪声压制干扰引入后, EIVDNet 能够检测出已学习干扰信号类型, 但存在少数将 NFMJ 误检为 SNJ 的情况; 而且结合图 12(a)~图 12(d) 结果可以看出, 未知干扰会影响现有干扰类型边框位置回归, 降低后续参数估计的准确性. 针对混叠干扰检测性能, 在 2~5 类干扰混叠情况下 EIVD-

Net 依然保持较为准确的检测性能, 但随着各类干扰信号重叠程度的增大, 模型检测的漏检情况愈发严重. 此外, 由于数据集中样本为单类电磁干扰信号, 故亦可验证所提 EIVDNet 检测模型能够适应小样本学习场景, 适用于雷达有源干扰信号捕获难、时间快、样本不足等实际应用环境.

表 6 未知与混叠干扰下检测结果

信号类型	样本数	真实检测数	正确检测数	漏检数	误检数
未知干扰+CSJ	25	25	25	0	0
未知干扰+DDJ	25	25	25	0	0
未知干扰+ISRJ	25	50	49	1	1
未知干扰+DFTJ	25	95	91	4	2
ISRJ+SNJ	25	100	94	6	0
ISRJ+SNJ+DFTJ	25	195	183	12	0
ISRJ+SNJ+DFTJ+CSJ	25	220	207	13	0
ISRJ+SNJ+DFTJ+CSJ+DDJ	25	245	234	11	0

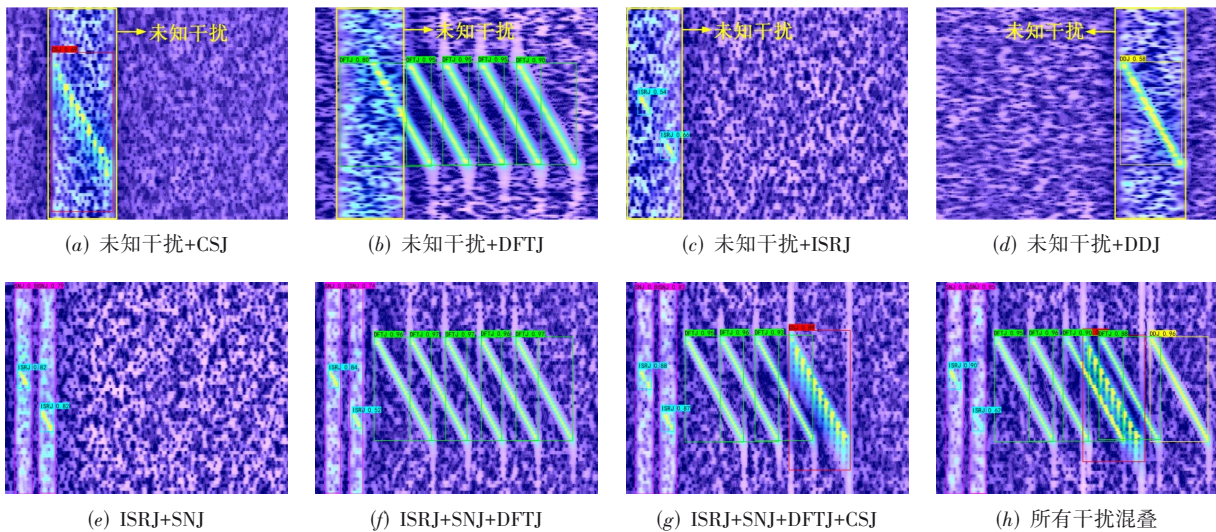


图 12 未知与混叠干扰情况下典型检测示例

5 结论

针对雷达系统所面临复杂电磁环境的挑战与威胁, 提出基于自适应对比度与边缘增强网络 ACEENet、电磁干扰视觉检测 EIVDNet 网络与 XGBoost 精准参数估计网络的高精度、低参量、实时干扰感知方法. 对于干扰类型检测, 所提 EIVDNet 模型检测精度 (mAP) 可达 99.30%, 且同时将计算量与参数量降低 18.41% 与 19.27%. 而对于干扰参数估计, 通过数值计算粗估计与 XGBoost 回归模型精确估计, 将总估计误差控制在 1.01%. 此外, 在 SNR 或 JNR 为 0 dB 时, 所提方法依然能够达到 93% 的检测精度与 8.28% 的总估计误差, 且在未知与混叠干扰情况下依然能够保持良好的可靠性. 结果表明, 所提方法有助于雷达系统对有源电磁干扰

的智能化感知, 结合相应抗干扰措施, 可以保证雷达平台系统的电磁兼容稳定性与认知抗干扰水平.

参考文献

- [1] 孟进, 张磊, 赵治华, 等. 新型舰船系统电磁干扰分析、测量与防护[M]. 北京: 电子工业出版社, 2020.
MENG J, ZHANG L, ZHAO Z H. Analysis, Measurement and Protection of Electromagnetic Interference of New Ship System[M]. Beijing: Publishing House of Electronics Industry, 2020. (in Chinese)
- [2] 张嘉毫, 李亚星, 郭宇, 等. 功率倒置准则下干扰对消空间分辨率分析及优化[J]. 中国电机工程学报, 2022, 42(13): 4665-4675.

- ZHANG J H, LI Y X, GUO Y, et al. Spatial resolution analysis and optimization of power-inversion based interference cancellation algorithm[J]. Proceedings of the CSEE, 2022, 42(13): 4665-4675. (in Chinese)
- [3] ZHOU W L, LV Z W, LI G Y, et al. Detection of spoofing attacks on global navigation satellite systems using Kolmogorov-Smirnov test-based signal quality monitoring method[J]. IEEE Sensors Journal, 2024, 24(7): 10474-10490.
- [4] ZHAO S S, ZHOU Y, ZHANG L R, et al. Discrimination between radar targets and deception jamming in distributed multiple-radar architectures[J]. IET Radar, Sonar & Navigation, 2017, 11(7): 1124-1131.
- [5] 张顺生, 陈爽, 陈晓莹, 等. 面向小样本的多模态雷达有源欺骗干扰识别方法[J]. 雷达学报, 2023, 12(4): 882-891.
- ZHANG S S, CHEN S, CHEN X Y, et al. Active deception jamming recognition method in multimodal radar based on small samples[J]. Journal of Radars, 2023, 12(4): 882-891. (in Chinese)
- [6] 檀鹏超. 雷达有源欺骗干扰多维特征提取与识别技术研究[D]. 成都: 电子科技大学, 2016.
- TAN P C. Research on Multi-dimensional Feature Extraction and Recognition Technology of Radar Active Deception Jamming[D]. Chengdu: University of Electronic Science and Technology of China, 2016. (in Chinese)
- [7] YU X, WANG W T, WU H, et al. Multi-domain feature fusion based radar deception jamming recognition method[C]//2023 IEEE 7th International Symposium on Electromagnetic Compatibility (ISEMC). Piscataway: IEEE, 2023: 1-4.
- [8] SU D T, GAO M G. Research on jamming recognition technology based on characteristic parameters[C]//2020 IEEE 5th International Conference on Signal and Image Processing (ICSIP). Piscataway: IEEE, 2020: 303-307.
- [9] WEI D X, ZHANG S N, CHEN S, et al. Research on anti-jamming technology of chaotic composite short range detection system based on underdetermined signal separation and spectral analysis[J]. IEEE Access, 2019, 7: 42298-42308.
- [10] ZHOU H P, WANG Z W, WU R W, et al. Jamming recognition algorithm based on variational mode decomposition[J]. IEEE Sensors Journal, 2023, 23(15): 17341-17349.
- [11] 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. (in Chinese)
- [12] 郎彬, 王欢, 宫健. 一种小样本数据驱动的雷达复合干扰轻量化感知网络[J]. 北京航空航天大学学报, 2024, 50(3): 1005-1014.
- LANG B, WANG H, GONG J. A small sample data-driven radar compound jamming lightweight perception network[J]. Journal of Beijing University of Aeronautics and Astronautics, 2024, 50(3): 1005-1014. (in Chinese)
- [13] 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.
- [14] TU Y, LIN Y, HOU C B, et al. Complex-valued networks for automatic modulation classification[J]. IEEE Transactions on Vehicular Technology, 2020, 69(9): 10085-10089.
- [15] ZHU M T, LI Y J, PAN Z S, 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.
- [16] ZHOU H P, WANG L, GUO Z Y. Recognition of radar compound jamming based on convolutional neural network[J]. IEEE Transactions on Aerospace and Electronic Systems, 2023, 59(6): 7380-7394.
- [17] LUO Z Y, CAO Y H, YEO T S, et al. Few-shot radar jamming recognition network via time-frequency self-attention and global knowledge distillation[J]. IEEE Transactions on Geoscience and Remote Sensing, 2023, 61: 5105612.
- [18] LV Q Z, QUAN Y H, SHA M H, et al. Deep neural network-based interrupted sampling deceptive jamming countermeasure method[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2022, 15: 9073-9085.
- [19] 杨伟超, 杨新权. 基于功率谱分布函数几何学分析的信号带宽估计[J]. 系统工程与电子技术, 2019, 41(5): 981-985.
- YANG W C, YANG X Q. Signal bandwidth estimation based on geometric analysis of power spectrum distribution function[J]. Systems Engineering and Electronics, 2019, 41(5): 981-985. (in Chinese)
- [20] WANG J Z, ZOU J W, SU S Y, et al. Detection and parameter estimation for space-borne radar linear frequency modulated pulse signal in low signal-to-noise ratio[J]. Journal of Applied Remote Sensing, 2015, 9(1): 095057.
- [21] WANG Z F, WANG Y, XU L. Parameter estimation of hybrid linear frequency modulation-sinusoidal frequency modulation signal[J]. IEEE Signal Processing Letters, 2023, 30: 1000000.

- 2017, 24(8): 1238-1241.
- [22] SU H N, BAO Q L, CHEN Z P. Parameter estimation processor for chirp signals based on a complex-valued deep neural network[J]. IEEE Access, 2019, 7: 176278-176290.
- [23] WEN C, PENG J Y, ZHOU Y, et al. Enhanced three-dimensional joint domain localized STAP for airborne FDA-MIMO radar under dense false-target jamming scenario[J]. IEEE Sensors Journal, 2018, 18(10): 4154-4166.
- [24] FENG D J, XU L T, PAN X Y, et al. Jamming wideband radar using interrupted-sampling repeater[J]. IEEE Transactions on Aerospace and Electronic Systems, 2017, 53(3): 1341-1354.
- [25] ZHANG Z L, WU Y N, REN J Q, et al. Smart noise jamming suppression by using atomic decomposition[C]//2017 3rd IEEE International Conference on Computer and Communications (ICCC). Piscataway: IEEE, 2017: 1377-1380.
- [26] GRIFFIN D, LIM J. Signal estimation from modified short-time Fourier transform[J]. IEEE Transactions on Acoustics, Speech, and Signal Processing, 1984, 32(2): 236-243.
- [27] WU F, FAN A, BAEVSKI A, et al. Pay less attention with lightweight and dynamic convolutions[EB/OL]. (2019-02-22) [2024-06-19]. <https://arxiv.org/abs/1901.10430>.
- [28] WANG C Y, BOCHKOVSKIY A, LIAO H M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2023: 7464-7475.
- [29] HE K M, ZHANG X Y, REN S Q, et al. Spatial Pyramid Pooling in Deep Convolutional Networks for Visual Recognition[M]//Computer Vision - ECCV 2014. Cham: Springer International Publishing, 2014: 346-361.
- [30] LI H L, LI J, WEI H B, et al. Slim-neck by GSConv: A lightweight-design for real-time detector architectures[EB/OL]. (2022-06-06)[2024-06-19]. <https://arxiv.org/abs/2206.02424>.
- [31] MISRA D, NALAMADA T, ARASANIPALAI A U, et al. Rotate to attend: Convolutional triplet attention module[C]//2021 IEEE Winter Conference on Applications of Computer Vision (WACV). Piscataway: IEEE, 2021: 3138-3147.
- [32] GEVORGYAN Z. SIOU loss: More powerful learning for bounding box regression[EB/OL]. (2022-05-25)[2024-06-19]. <https://arxiv.org/abs/2205.12740>.
- [33] ZHANG Y F, REN W Q, ZHANG Z, et al. Focal and efficient IOU loss for accurate bounding box regression[J]. Neurocomputing, 2022, 506: 146-157.
- [34] CHEN T Q, GUESTRIN C. XGBoost: A scalable tree boosting system[C]//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2016: 785-794.
- [35] ZHU X, WU H, HE F M, et al. YOLO-CJ: A lightweight network for compound jamming signal detection[J]. IEEE Transactions on Aerospace and Electronic Systems, 2024, 60(5): 6807-6821.
- [36] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.
- [37] ZHANG L P, LIU Y, ZHAO W D, et al. Frequency-adaptive learning for SAR ship detection in clutter scenes[J]. IEEE Transactions on Geoscience and Remote Sensing, 2023, 61: 5215514.
- [38] WU M H, LI M L, SHI H R, et al. Using range-Doppler spectrum-based deep learning method to detect radar target in interrupted sampling repeater jamming[J]. IEEE Sensors Journal, 2023, 23(23): 29084-29096.
- [39] GE Z, LIU S T, WANG F, et al. YOLOX: Exceeding YOLO series in 2021[EB/OL]. (2021-08-06) [2024-06-19]. <https://arxiv.org/abs/2107.08430>.

作者简介



朱 轩 男, 1996年出生于江西省. 现为武汉大学电气与自动化学院博士研究生. 主要研究方向为信号处理、计算机视觉、干扰识别与参数估计.

E-mail: zhuxuan1996@whu.edu.cn



吴 灏 男, 1988年出生于安徽省. 现为海军工程大学电磁能技术全国重点实验室副研究员. 主要研究方向为信号处理、波形设计、机器学习等.

E-mail: wowhow@163.com