

时频增强与轻量化网络的无人机射频信号检测

王巍^{1,2}, 史众楷^{1,2}, 孙闽红¹, 杨少飞², 沈伟国^{2,3}

(1.杭州电子科技大学 通信工程学院, 浙江 杭州 310018; 2.电磁空间安全全国重点实验室, 浙江 嘉兴 314033; 3.复旦大学未来信息创新学院, 上海 200433)

摘要: 针对低信噪比下无人机射频时频图目标能量弱、易漏检和检测网络冗余的问题, 提出一种时频增强与轻量检测联合方法。该方法基于自适应前景掩膜、多尺度能量密度和连通域内部权重选择性增强目标区域, 并通过 P2/P5 尺度重构、Ghost 骨干、SlimNeck 和共享解耦检测头构建 RF-YOLO-Lite。实验结果表明, 该方法在仿真数据集上 mAP@0.5 和 mAP@0.5:0.95 分别为 94.85% 和 79.86%, 参数量为 1.39×10^6 , GFLOPs 为 5.4; 在 DroneRFa 实采加噪数据上具有较好的低信噪比鲁棒性。

关键词: 无人机射频信号; 轻量化目标检测; 低信噪比; 时频增强

中图分类号: TN975

文献标志码: A

doi: 10.11959/j.issn.1000

UAV RF signal detection based on time-frequency enhancement and a lightweight detection network

Wang Wei^{1,2}, Shi Zhongkai^{1,2}, Sun Minhong¹, Yang Shaofei², Shen Weiguo^{2,3}

1. School of Communication Engineering, Hangzhou Dianzi University, Hangzhou 310018, China

2. National Key Laboratory of Electromagnetic Space Security, Jiaxing 314033, China

3. College of Future Information Technology, Fudan University, Shanghai 200433, China

Abstract: To address weak target energy, missed detection, and network redundancy in unmanned aerial vehicle (UAV) radio-frequency (RF) time-frequency map detection under low signal-to-noise ratio (SNR) conditions, a joint method combining time-frequency enhancement and lightweight detection was proposed. The proposed method selectively enhanced target-related regions using an adaptive foreground mask, multi-scale energy density, and connected-component interior weighting. RF-YOLO-Lite was then constructed through P2/P5 scale reconstruction, a Ghost-based backbone, SlimNeck feature fusion, and a lightweight shared decoupled detection head. Experimental results show that the proposed method achieves 94.85% mAP@0.5 and 79.86% mAP@0.5:0.95 on the simulated dataset, with 1.39×10^6 parameters and 5.4 GFLOPs. Experiments on the noisy DroneRFa measured dataset further demonstrate its robustness under low-SNR degradation. The method provides a favorable trade-off between detection accuracy and computational complexity.

Key words: UAV RF signal, lightweight object detection, low SNR, time-frequency enhancement

0 引言

近年来, 无人机在航拍测绘、物流运输和军事侦察等领域广泛应用, 推动了低空经济与智慧城市的快速发展^[1-3]。与此同时, “低慢小” 无人机在复

杂城市环境中的活动引发空域安全与隐私风险, “黑飞”、机场运行干扰及非法航拍侦察等行为对公共安全与国家安全构成威胁^[4]。实现对违规无人机的快速感知与预警, 当前主要采用雷达探测、光电

收稿日期: 2026-04-24; 修回日期: 2026-07-20

通信作者: 沈伟国, beyondswg@163.com

成像、声学探测以及基于射频信号的探测等技术手段^[5-8]。其中, 基于控制链路与图传链路射频特征的检测不依赖视距、适用于全天候监测且对目标几何尺寸不敏感, 因而成为重要研究方向^[9]。

早期射频信号检测多依赖传统信号处理方法, 如能量检测、匹配滤波与循环平稳分析等^[10]。然而, 在复杂电磁环境下, 此类方法对先验信息依赖较强, 且对宽带干扰、时变信道与突发跳频等情形鲁棒性不足, 难以兼顾高精度与实时性。近年来, 随着深度学习技术的发展, 将射频信号转换为时频图、功率谱图或瀑布图, 并利用卷积神经网络和目标检测网络进行信号定位与识别, 已成为射频智能感知的重要技术路线。已有研究表明, 宽带射频信号可以在 complex spectrogram 或 PSD waterfall 图像上进行检测、定位和识别, 目标检测网络和分割网络均可用于提取信号在时间-频率平面上的占用区域^[11-13]。例如, DFN-YOLO 面向宽带频谱中的窄带信号盲检测问题, 在 YOLO 框架中引入变形特征增强思想, 以增强复杂宽带背景下窄带信号的检测能力^[14]。上述研究说明, 射频时频图检测已经不再只是简单套用自然图像检测模型, 而是逐渐开始结合频谱信号形态、弱目标特征和复杂背景干扰进行任务适配性改进。

在无人机射频检测方面, 现有研究多以无人机存在性判别、类型识别或个体识别等分类任务为主, 通常关注“属于哪一类无人机信号”, 而直接面向无人机射频时频图目标区域定位的检测研究相对较少。Delleji 等提出 RF-YOLO, 将无人机与遥控器之间的射频通信信号表示为 spectrogram 图像, 并采用改进 YOLO 实现无人机检测与分类, 验证了目标检测网络在无人机射频时频图任务中的可行性^[15]。同时, DroneRFa、RFUAV 等公开无人机射频数据集的提出, 为无人机 RF 检测与识别提供了实采数据基础^[16-17]。然而, 现有无人机射频研究对时频图检测任务中的弱目标增强、检测尺度适配和轻量化网络设计关注仍不充分。无人机射频目标通常由宽带图传链路、窄带控制链路和跳频控制片段共同构成, 在时频平面上表现为连续能量带、离散跳频点和局部弱能量块等复合结构。特别是在低信噪比和强背景干扰条件下, 这些目标往往具有尺度小、能量弱、边界模糊和形态稀疏等特点, 直接采用通用目标检测网络容易出现弱小目标漏检和定位

不稳定问题。

除检测网络外, 前端时频图增强也是影响低信噪比检测性能的重要环节。常见的图像增强、滤波去噪和小波去噪方法能够在一定程度上抑制随机噪声, 但射频时频图并非普通自然图像, 其像素强度反映局部信号能量分布, 纹理结构对应具体的时间-频率占用关系。若直接套用自然图像增强策略, 可能在抑制噪声的同时削弱窄带谱线、跳频片段和低能量目标边缘, 甚至破坏原有时频结构^[18]。因此, 面向无人机射频时频图的增强方法不应仅追求视觉对比度提升, 而应结合信号能量聚集性、局部连通性和目标区域内部结构进行设计, 以增强弱目标显著性并避免背景噪声同步放大。

另一方面, 低空无人机监测通常面向边缘感知设备、便携式监测平台或机载处理终端, 对模型参数量、计算复杂度和推理速度提出较高要求。现有 YOLO 系列模型虽然具有较好的检测精度和实时性^[19], 但直接用于无人机射频时频图检测时仍存在两方面问题: 一是原始检测尺度主要面向自然图像中多尺度目标设计, 对时频图中窄带谱线、短时跳频片段和小尺度能量块的适配性不足; 二是通用网络中的骨干、颈部和检测头仍包含一定冗余计算, 难以在资源受限平台上兼顾低信噪比检测精度与轻量化部署需求。已有轻量化结构如 GhostNet、SlimNeck 等为降低网络冗余计算提供了可借鉴思路^[20-21], 但如何结合无人机射频时频图的弱小目标形态, 对检测尺度、特征融合结构和检测头进行任务适配性重构, 仍有进一步研究空间。

基于上述问题, 本文针对复杂频谱环境下低信噪比无人机射频信号的时频检测开展研究, 主要贡献如下:

1) 面向低信噪比无人机射频时频图检测任务, 构建可控复合射频实验场景, 并补充引入 DroneRFa 公开实采数据集开展低信噪比退化验证。前者用于系统分析宽带图传、窄带控制和跳频片段等复合信号在不同噪声与干扰条件下的检测性能; 后者通过将实采射频信号转换为 STFT 时频图并进行目标边界框标注, 形成适用于检测任务的实采时频图样本, 用于补充评估所提方法在真实无人机射频信号低信噪比退化条件下的适用性和鲁棒性。

2) 提出多尺度能量密度引导时频增强 (multi-scale energy density enhancement, MEDE) 方法。

该方法在 STFT 时频表示上引入自适应前景掩膜、多尺度局部能量密度估计和连通域内部性建模,仅对具有目标能量聚集特征的前景区域施加非线性增益,从而提升低 SNR 条件下无人机射频弱目标在时频平面中的显著性,并降低背景噪声和边缘误增强对检测结果的影响。

3) 设计面向无人机射频时频图的轻量化检测网络 RF-YOLO-Lite。针对无人机射频目标尺度小、纹理细弱和大尺度目标占比低的特点,引入 P2 小目标检测层并裁剪 P5 直接检测分支,同时结合 Ghost 轻量骨干、SlimNeck 多尺度融合结构和轻量共享解耦检测头,在提升弱小目标检测能力的同时降低参数量与计算量,为后续端侧部署提供轻量化基础。

1 信号时频表示与能量密度增强

1.1 基于 STFT 的时频分析

为表征无人机射频信号的时频联合特性,本文对降采样后的复基带信号进行短时傅里叶变换(short-time Fourier transform, STFT),构建时频表示。设降采样输出信号为 $y(t)$,离散化后记为 $y(n)$, k 表示频率索引, t 表示时间帧索引,则 STFT 可写为:

$$\hat{y}(k, t) = \sum_n y(n) g(t - n) e^{-j2\pi kn/N_m} \quad (1)$$

式中: $g(\cdot)$ 为窗函数, N_m 为快速傅里叶变换长度。将 $\hat{y}(k, t)$ 按帧索引 t 组织即可得到复基带信号在时间-频率平面上的二维表示。

与传统功率谱相比, STFT 时频图可同时刻画瞬时带宽、中心频率演化与局部能量分布,为后续增强与检测提供基础表征。但在低信噪比条件下,目标在时频图上往往稀疏且尺度细小,目标与背景噪声/宽带干扰的对比度降低,直接基于原始 STFT 图检测易出现能量淹没与干扰混淆。为缓解上述问题,本文提出 MEDE 方法,对弱目标区域自适应增益并抑制背景,从而提升时频显著性。

本文在生成时频图时采用统一 STFT 参数,以保证不同样本之间的时频表示具有一致尺度。窗函数选用 Hamming 窗,窗长设置为 2048 点,相邻帧重叠率为 75%,FFT 点数设置为 4096。Hamming 窗能够在频谱泄漏抑制与主瓣宽度之间取得较好平衡;2048 点窗长兼顾时间分辨率与频率分辨率;

75% 帧重叠有助于保持相邻时间帧之间的连续性,降低弱短时信号片段在分帧过程中的信息损失;4096 点 FFT 则用于提高频率轴采样密度,使窄带控制链路和局部跳频片段在时频图中具有更清晰的频率结构。为保证公平性,本文所有样本及所有 SNR 条件下均采用相同 STFT 参数,不针对不同信噪比单独调整。

1.2 多尺度能量密度引导时频增强(MEDE)

为提升低信噪比条件下无人机射频信号在时频平面中的可检测性,本文在短时傅里叶变换(STFT)幅度谱基础上提出 MEDE。该方法以 STFT 复谱 $\hat{y}(k, t)$ 为输入,输出增强幅度谱 $A^{enh}(k, t)$ 及增益谱 $G(k, t)$ 。其核心思想是:从幅度显著性中自适应提取前景候选区域;在多个时间-频率尺度上估计局部能量密度以刻画能量聚集程度;引入连通域内部性权重抑制边缘过渡区域的误增强;最终仅对前景区域施加非线性增益,实现目标纹理凸显与背景抑制的统一。

步骤1 幅度显著性构建。为提高低信噪比条件下无人机射频目标在时频平面中的可分辨性,首先对 STFT 复谱 $\hat{y}(k, t)$ 求幅度 $A(k, t) = |\hat{y}(k, t)|$ 并在 dB 域进行对数压缩,以减弱幅度动态范围过大对后续显著性建模的不利影响。具体地,定义

$$A_{\log}(k, t) = 20 \log_{10}(A(k, t) + \varepsilon) \quad (2)$$

其中 ε 为防止对数奇异的微小常数。

考虑到时频图中可能存在少量异常强干扰分量或突发高能量点,若直接以全局最大值作为裁剪上界,容易导致整体对比度被极少数强响应主导,从而压缩弱目标纹理的可见性。为此,本文采用 dB 幅度谱的高分位数作为鲁棒参考上界,记为

$$A_{\text{ref}} = \text{Quantile}(A_{\log}, q_{\text{ref}}) \quad (3)$$

其中, $\text{Quantile}(A_{\log}, q_{\text{ref}})$ 表示 $A_{\log}$ 的 q_{ref} 分位数,用于给出对异常强分量不敏感的参考幅度水平。在此基础上,对 $A_{\log}(k, t)$ 进行动态范围裁剪,得到

$$A_{\text{dB}}(k, t) = \min(\max(A_{\log}(k, t), A_{\text{ref}} - D), A_{\text{ref}}) \quad (4)$$

其中,裁剪区间为 $[A_{\text{ref}} - D, A_{\text{ref}}]$,参数 D 表示围绕鲁棒参考上界向下保留的有效动态范围。其物理意义在于:在抑制异常强分量主导效应的同时,为低能量无人机目标纹理保留足够的对比度空间。当 D 取值较小时,仅有接近主能量簇的强响应区域得以保留,弱目标条带或低能量跳频片段可能被进一步

压缩；当 D 取值过大时，更多背景噪声和宽带干扰被保留，削弱目标与背景之间的显著性差异。因此， D 本质上控制了弱目标增强与背景抑制之间的平衡。

进一步地，对裁剪后的幅度谱 $A_{\text{dB}}(k,t)$ 进行线性归一化，得到显著性矩阵

$$S(k,t) = \text{Norm}(A_{\text{dB}}(k,t)), \quad S(k,t) \in [0,1] \quad (5)$$

其中 $\text{Norm}(\cdot)$ 采用 $\min - \max$ 归一化。经上述处理后，原始时频幅度被映射为具有统一数值范围的显著性表示，使弱目标能量簇在抑制极强干扰背景的同时获得更稳定的对比度，为后续自适应前景掩膜生成和多尺度局部能量密度估计提供基础。

步骤2 自适应前景掩膜生成与净化。为提高前景提取在不同信噪比与干扰条件下的适应性，本文不采用固定阈值，而是依据当前时频图显著性矩阵 $S(k,t)$ 的统计分布自适应确定门限。具体地，定义

$$\tau_q = \text{Quantile}(S, q) \quad (6)$$

其中， $\text{Quantile}(S, q)$ 表示显著性矩阵 S 的 q 分位数，即满足约有 q 比例元素不大于该值的统计量。由此构造初始前景掩膜

$$M(k,t) = S(k,t) \geq \tau_q \quad (7)$$

采用分位数门限的原因在于：不同样本在整体能量水平、噪声强度及干扰分布上存在明显差异，若使用固定阈值，则难以同时适应高信噪比与低信噪比场景；而分位数门限能够根据当前时频图的显著性分布自动调节前景筛选强度，从而增强方法的鲁棒性。参数 q 用于控制前景掩膜的保守程度：当 q 取值较大时，仅保留显著性较高的能量聚集区域，能够有效抑制背景噪声引入，但可能造成弱目标边缘信息缺失；当 q 取值较小时，更多低显著性区域被纳入前景，虽有利于保留弱纹理结构，但也更容易引入散点噪声。考虑到无人机射频信号在时频图中通常呈现为面积占比较小、能量分布稀疏的图传块和跳频控制片段，本文采用较高分位数门限以获得更稳定的前景候选区域。

进一步地，为去除由噪声波动引起的离散伪前景并改善掩膜边界的连续性，对初始掩膜 $M(k,t)$ 进行净化处理，得到

$$\hat{M}(k,t) = \text{Clean}(M(k,t)) \quad (8)$$

其中 $\text{Clean}(\cdot)$ 表示连通域面积剔除与形态学开闭运算的组合操作，用于去除离散噪点并平滑边界，从而保证前景区域的连贯性与稳定性。其中，连通域面积剔除用于删除面积小于阈值 T_{area} 的孤立噪声块；形态学开闭运算采用大小为 $r \times r$ 的结构元素实现。

步骤3 多尺度局部能量密度估计。为刻画无人机射频目标在时频平面中的局部能量聚集性，本文在净化后的前景掩膜 $\hat{M}(k,t)$ 约束下，对显著性矩阵 $S(k,t)$ 进行多尺度二维局部统计。具体地，先通过 $\hat{M}(k,t) \odot S(k,t)$ 保留候选前景区域内的显著性响应，以减弱背景噪声对局部统计的干扰；随后，采用不同尺度的二维卷积核 $K^{(l)}$ 对其进行平滑，得到第 l 个尺度下的局部能量密度响应

$$D^{(l)}(k,t) = \text{Norm}\left(K^{(l)} * \left(\hat{M}(k,t) \odot S(k,t)\right)\right) \quad (9)$$

其中， $l = 1, 2, \dots, L$ ； $D^{(l)}(k,t)$ 表示时频点 (k,t) 在第 l 个邻域尺度下的局部能量密度响应。其取值越大，说明该点越可能位于局部连续且稳定的目标能量簇中。

采用多尺度而非单尺度统计，主要是由于无人机射频信号在时频图中兼具宽带图传块、短时跳频片段等多种形态。较小尺度有利于保持细粒度弱纹理，较大尺度有利于描述连续能量团簇。多尺度局部能量密度估计因此能够同时兼顾细节保持与整体聚集建模，从而提升低信噪比条件下目标区域的可分辨性。

步骤4 内部性权重与融合权重形成。仅依赖局部能量密度响应 $D^{(l)}(k,t)$ 进行增强，容易在前景连通块边缘产生过增强现象。为此，本文在净化后的前景掩膜 $\hat{M}(k,t)$ 上执行距离变换，并归一化得到内部性权重矩阵

$$W_{\text{in}}(k,t) = \text{DistNorm}(\hat{M}(k,t)) \quad (10)$$

其中 $\text{DistNorm}(\cdot)$ 表示计算前景像素到最近背景像素的欧氏距离并归一化到 $[0,1]$ ，背景处取0。该权重反映像素位于前景连通域内部的程度：距离边界越远，内部性越强，越可能对应目标主体区域；越接近边界，则越易受到背景噪声和区域过渡效应影响。在此基础上，将内部性权重与各尺度局部能量密度响应进行线性融合，并在尺度维上取最大响应，得到统一权重

$$W(k, t) = \text{Norm} \left(\max_{1 \leq l \leq L} (\alpha W_{\text{in}}(k, t) + (1 - \alpha) D^{(l)}(k, t)) \right) \quad (11)$$

其中, $\alpha \in [0, 1]$ 为平衡系数。该设计能够在突出目标能量聚集区域的同时降低边缘噪声被过度增强的风险。

步骤 5 非线性增益映射与幅度增强。依据统一权重 $W(k, t)$ 构造仅作用于前景区域的非线性增益函数:

$$G(k, t) = \begin{cases} G_{\min} + (G_{\max} - G_{\min}) W(k, t)^\gamma, & \hat{M}(k, t) = 1 \\ 0, & \hat{M}(k, t) = 0 \end{cases} \quad (12)$$

其中 $[G_{\min}|G_{\max}]$ 为预设增益区间, γ 控制增益映射的非线性强度。该设计使背景区域不被增强, 从而避免噪声和干扰被同步放大; 同时, 通过非线性映射使高权重区域获得更集中、更显著的增益, 以突出目标核心结构。随后, 在幅度域完成增强:

$$A^{\text{enh}}(k, t) = A(k, t) \cdot 10^{G(k, t)/20} \quad (13)$$

该映射保证增强主要分配给具有多尺度能量聚集特征且位于连通域内部的时频区域, 从而提升低信噪比条件下弱目标的显著性, 并降低背景噪声与边缘误增强对后续检测的影响。

MEDE 中涉及的主要参数包括 dB 幅度谱参考分位数 q_{ref} 、前景分位数门限 q 、dB 域动态范围 D 、多尺度局部统计核 $K^{(l)}$ 、内部性融合权重 α 、增益区间 $[G_{\min}|G_{\max}]$ 、非线性指数 γ 、连通域面积阈值

T_{area} 以及形态学结构元素半径 r 。为避免针对不同测试样本或不同 SNR 条件进行人工调参, 本文在所有实验中均采用统一参数设置。具体参数如表 1 所示。

图 1 给出了典型样本的增强过程与中间结果: 图 1 (a) 为原始时频图, 在强噪声背景下目标纹理结构对比度较低; 图 1 (b) 为前景掩膜谱 $\hat{M}(k, t)$, 能够自适应定位疑似目标区域并抑制离散噪点; 图 1 (d) 为增益谱 $G(k, t)$, 其高增益主要集中于目标对应的连通块内部区域, 背景区域保持接近零增益; 因此增强后的时频图 (图 1 (c)) 中目标条纹/纹理结构得到显著凸显, 而宽带噪声与非目标散点被有效抑制。上述结果表明, MEDE 可在不引入复杂先验的情况下提升低信噪比时频表征的可分辨性, 为后续检测网络提供更具判别力的输入特征。

2 RF-YOLO-Lite 检测网络

2.1 YOLOv11 基线网络

YOLOv11 是 Ultralytics 发布的新一代目标检测网络, 在检测精度、参数规模和推理速度之间具有较好的综合性能。考虑到无人机射频时频图检测任务对实时性和轻量化具有较高要求, 本文选取 YOLOv11n 作为基线模型。

YOLOv11 整体结构由骨干网络 (Backbone)、颈部网络 (Neck) 和检测头 (Head) 三部分组成。骨干网络负责多尺度特征提取, 通过卷积模块、C3k2 模块、SPPF 模块和 C2PSA 模块逐级提取由浅层纹理到高层语义的特征表示; 颈部网络采用 FPN+PAN 的双向特征融合结构, 将不同尺度的语

表 1

参数设置说明

参数	取值	含义	选择依据
q_{ref}	0.995	dB 幅度谱参考分位数	抑制异常强响应对动态范围裁剪的影响
q	0.90	前景分位数门限	平衡弱目标保留与噪声抑制
D	60 dB	dB 域动态范围	保留弱目标纹理, 同时抑制低能量背景
$K^{(l)}$	$3 \times 3, 5 \times 5, 9 \times 9$	不同尺度的二维卷积核	兼顾窄带谱线、短时跳频片段和宽带图传能量带的不同尺度结构
α	0.35	内部性权重融合系数	以能量密度为主, 抑制边缘过增强
$G_{\min}$	8 dB	最小增强增益	避免前景区域增强不足
$G_{\max}$	32 dB	最大增强增益	提升弱目标显著性, 避免过增强
γ	1.2	非线性增益指数	使高权重区域获得更集中增强
T_{area}	3 像素	连通域面积筛选阈值	去除孤立噪点
r	2	形态学闭运算结构元素半径	平滑前景掩膜边界




图1 MEDE方法

义信息和细节信息进行融合；检测头在P3、P4和P5三个尺度上完成边界框回归和类别预测。YOLOv11模型结构示意图见图2。




图2 YOLOv11模型结构

2.2 RF-YOLO-Lite总体结构设计

针对无人机射频时频图中目标尺度小、能量弱、形态稀疏且背景干扰复杂的特点，本文围绕检测尺度、骨干网络、特征融合结构和检测头四个方面对YOLOv11n进行任务适配性改进，构建RF-YOLO-Lite。其总体结构如图3所示。

在检测尺度方面，本文引入高分辨率P2检测层，以增强网络对窄带谱线、弱小跳频片段和局部能量块的定位能力；同时裁剪原始P5直接检测分支，仅保留P5高层语义特征参与后续特征融合，从而减少与本文目标尺度分布不匹配的大尺度检测




图3 RF-YOLO-Lite模型结构

开销。在骨干网络方面，采用Ghost模块对部分C3k2特征提取单元进行轻量化替换，以降低通道冗余和参数规模。在颈部网络方面，引入基于GSConv和VoV-GSCSP的SlimNeck结构，在保持跨尺度信息传递能力的同时减少特征融合阶段的计算开销。在检测头方面，采用轻量共享解耦检测头Detect_LSDECD，通过通道统一和跨尺度共享细节增强卷积减少多尺度预测端的重复计算^[22]。

由此，RF-YOLO-Lite并非对YOLOv11n的简单压缩，而是根据无人机射频时频图目标形态进行的协同结构重构。P2/P5尺度调整用于增强小目标适配性，Ghost用于压缩骨干冗余计算，SlimNeck用于降低多尺度融合成本，Detect_LSDECD用于减少检测头重复参数。上述设计共同实现了检测精度、参数量、计算复杂度和推理效率之间的平衡。

2.3 P2小目标检测层与P5检测头裁剪设计

无人机射频信号在时频图中通常表现为窄带谱线、短时跳频片段和细长能量带。这类目标在空间上占比小、纹理细弱,在低信噪比条件下容易被背景噪声或宽带干扰淹没。若仅使用YOLOv11原有的P3、P4和P5三个检测尺度,浅层高分辨率特征在多次下采样过程中容易丢失,导致弱小目标边界模糊、响应减弱或直接漏检。

为增强网络对细粒度时频结构的感知能力,本文在原有尺度检测框架中增加P2检测层。P2特征图具有更高空间分辨率,能够更好地保留窄带谱线、离散跳频点和局部弱能量块的位置信息,有利于提升低信噪比条件下的小目标检出能力。

与此同时,本文裁剪P5的直接检测分支。与自然图像检测中大、中、小目标并存的情况不同,本文数据中的有效射频目标主要集中于小尺度和中小尺度区域,大尺度完整目标占比较低。P5检测头对应低分辨率特征图,更偏向大范围语义区域建模,其直接检测作用与本文目标尺度分布不完全匹配。因此,本文保留P5高层特征参与上采样和跨尺度融合,但取消其直接检测输出,以减少大尺度预测分支带来的冗余计算。

综上,本文采用“引入P2、裁剪P5直接检测头”的尺度重构策略。该策略并非简单增加或减少检测尺度,而是在保留高层语义辅助作用的前提下,将检测资源更多分配给与无人机射频时频图目标形态更匹配的P2、P3和P4尺度,从而提升弱小目标检测能力并控制模型复杂度。

2.4 基于Ghost的轻量骨干网络

无人机射频时频图中的目标纹理相对规则,主要由窄带谱线、短时跳频片段和局部连续能量带构成。与自然图像中复杂语义目标相比,此类时频纹理在不同通道之间更容易产生相似响应,骨干网络中存在一定冗余特征计算。因此,本文在保持YOLOv11n骨干网络层级结构稳定的基础上,引入Ghost模块对部分特征提取单元进行轻量化替换。

Ghost模块的基本结构如图4所示。该模块首先通过少量标准卷积生成固有特征,再利用廉价线性变换生成派生特征,最后将二者在通道维度进行组合输出。相比完全依赖标准卷积的特征生成方式,Ghost模块能够在保持输出通道数不变的情况下降低参数量和理论计算量。




图4 GhostModule结构图

考虑到浅层特征对弱小目标边缘和细粒度纹理较为敏感,本文并未对骨干网络进行全局Ghost化替换,而是采用选择性替换策略。具体而言,输入端两层标准卷积、SPPF模块和C2PSA模块保持不变,仅将Backbone各阶段中的C3k2特征提取模块替换为C3k2_GhostConv。具体替换位置如表2所示。

表2 Ghost模块在骨干网络中的替换位置

层号	YOLOv11n 结构	改进后结构	输出尺 度	输入 通道	输出 通道
2	C3k2	C3k2_GhostConv	P2/4	32	64
4	C3k2	C3k2_GhostConv	P3/8	64	128
6	C3k2	C3k2_GhostConv	P4/16	128	128
8	C3k2	C3k2_GhostConv	P5/32	256	256

由表2可见,Ghost模块主要嵌入P2/4、P3/8、P4/16和P5/32四个阶段的C3k2特征提取单元中。这些位置承担主要通道变换任务,是骨干网络参数量和计算量较集中的部分。通过在这些阶段引入C3k2_GhostConv,可压缩中间特征提取过程中的冗余卷积计算;同时保留下采样卷积、SPPF和C2PSA等关键模块,可避免过度轻量化导致浅层纹理细节或高层语义表达受损。因此,Ghost模块在本文网络中的主要作用是降低骨干网络冗余计算,并为P2高分辨率检测分支和后续多尺度特征融合预留计算预算。

2.5 基于SlimNeck的多尺度特征融合结构

引入P2检测层后,网络需要在更高分辨率特征图上进行跨尺度融合和预测,计算量与访存开销随之增加。为在保持弱小目标表征能力的同时降低Neck部分的融合成本,本文采用基于GSCov和VoV-GSCSP的SlimNeck结构替换YOLOv11n中部分特征融合模块。

GSCov由标准卷积分支和轻量卷积分支组成。

标准卷积分支用于保留跨通道信息交互能力, 轻量卷积分支用于降低局部空间特征提取的计算开销, 两支路输出经拼接和通道重排后形成融合特征。相比直接使用深度可分离卷积, GSConv 在降低计算量的同时保留了较好的通道混合能力, 更适合用于多尺度特征融合阶段。图 5 给出了轻量卷积的基本示意, 图 6 进一步展示了 GSConv 的结构。




图 5 轻量卷积示意图

在 GSConv 的基础上, 本文采用 VoV-GSCSP 作为 Neck 中的核心融合单元, 其结构如图 7 所示。VoV-GSCSP 采用跨阶段双分支结构: 一条分支通过 GS Bottleneck 提取局部结构和通道混合特征, 另一条分支保留输入特征中的原始纹理响应, 随后将两支路特征拼接并通过卷积完成通道整合。该设计能够在降低 Neck 计算量的同时减轻弱纹理在多尺度融合过程中的信息损失。

本文中 SlimNeck 的具体使用位置如表 3 所示。

VoV-GSCSP 主要布置在各尺度 Concat 操作之后, 用于替换原 YOLOv11n Neck/Head 中的 C3k2 融合模块; GSConv 主要用于 PAN 自底向上路径中的下采样融合位置, 用于替代部分标准下采样卷积。

具体而言, 在自顶向下路径中, P5 高层语义特征首先上采样并与 P4 特征拼接, 经 VoV-GSCSP 完成跨尺度融合; 随后继续上采样并与 P3 特征拼接, 再经 VoV-GSCSP 输出 P3 融合特征; 最后进一步上采样至 P2 尺度, 与浅层高分辨率特征拼接后通过 VoV-GSCSP 形成 P2 检测特征。该路径主要用于将高层语义信息传递至浅层高分辨率特征, 以增强小尺度弱目标的语义感知能力。

在自底向上路径中, P2 融合特征首先通过 GSConv 下采样并与 P3 融合特征拼接, 经 VoV-GSCSP 形成 P3 检测特征; 随后 P3 融合特征继续通过 GSConv 下采样并与 P4 融合特征拼接, 经 VoV-GSCSP 形成 P4 检测特征。该路径主要用于将浅层细粒度定位信息回传至中高层尺度, 以提高不同尺度检测特征的结构一致性。

2.6 轻量共享解耦检测头 Detect_LSDECD

常规多尺度解耦检测头通常在每个检测尺度上分别构建分类分支和回归分支。该结构有利于分类和定位任务分离, 但在 P2、P3 和 P4 等多个尺度上会重复引入卷积计算。考虑到无人机射频时频图中不同尺度目标均主要表现为条带状、块状或短时段状纹理, 其局部结构具有一定相似性, 检测头中的部分细节增强过程具备跨尺度共享的可能。

为此, 本文采用轻量共享解耦检测头 Detect_LSDECD 对预测端进行重构, 其结构如图 8 所示。该检测头首先使用 GN_Conv 1×1 对 P2、P3




图 1 GSConv 结构示意图




图7 VoV-GSCSP结构图

表3 SlimNeck在RF-YOLO-Lite Neck/Head中的使用位置

层号	YOLOv11n 结构	改进后结构	输出尺 度	输入通 道	输出通 道
13	C3k2	VoVGSCSP	P4/16	384	128
16	C3k2	VoVGSCSP	P3/8	256	64
19	C3k2	VoVGSCSP	P2/4	128	32
20	Conv	GSConv	P3/8	32	32
22	C3k2	VoVGSCSP	P3/8	96	64
23	Conv	GSConv	P4/16	64	64
25	C3k2	VoVGSCSP	P4/16	192	128

和P4三个尺度的输入特征进行通道对齐，将其统一映射到隐藏通道数 $hidc$ 。在本文配置中，Detect_LSDECD的基准隐藏通道数为256，经YOLOv11n宽度系数缩放后，实际 $hidc$ 为64。因此，三个检测尺度在进入共享细节增强卷积前均被统一调整为64个通道。

完成通道对齐后，各尺度特征共用同一套DEConv_GN 3×3 细节增强卷积进行特征提取。本文的共享卷积由两个连续的DEConv_GN模块组成，其输入和输出通道数均为64。与为每个尺度单独建立卷积增强分支不同，该设计在P2、P3和P4三个检测尺度之间共享细节增强参数，从而减少多尺度检测头中的重复计算。

在共享增强之后，Detect_LSDECD仍保留解耦检测形式，分别通过独立的 1×1 卷积分支输出边界框回归结果和类别预测结果。其中，边界框回归分支输出通道数为 $4 \times reg_{max}$ ，本文设置 $reg_{max} = 16$ ，因此回归分支输出通道数为64；分类分支输出通道数为类别数 n_c ，本文采用单类别无人机射频目标标注，因此 $n_c = 1$ 。此外，回归分支后设置尺

度因子Scale，用于对不同检测尺度上的边界框回归输出进行自适应调整。

综上，Detect_LSDECD通过“通道统一—共享增强—解耦预测”的方式降低预测端冗余计算。对于本文任务，不同尺度射频目标具有相似的局部时频纹理，跨尺度共享细节增强卷积能够在较低参数量下提取一致的时频结构特征，从而在保持检测头预测能力的同时降低模型规模和计算复杂度。




图8 Detect_LSDECD结构图

需要说明的是，RF-YOLO-Lite中各结构改动并非相互独立的简单叠加，而是围绕无人机射频时频图的目标形态与轻量化需求形成的协同设计。P2检测层用于强化浅层高分辨率特征对细粒度弱纹理的感知能力，P5直接检测分支裁剪用于减少与任务相关性较低的大尺度预测开销；Ghost模块用于压缩骨干网络中由规则时频纹理带来的通道冗余；SlimNeck用于在较低计算开销下完成浅层定位细节与高层语义信息的双向融合；Detect_LSDECD则进一步减少多尺度检测头中的重复卷积计算。上述模块分别作用于检测尺度、骨干特征提取、颈部特征融合和预测端轻量化，共同构成面向低信噪比无人机射频时频图检测的RF-YOLO-Lite网络。

3 实验设置

3.1 实验数据集

为在可控条件下评估复杂电磁环境中的检测性能，本文基于典型无人机通信与图传场景构建复合射频信号仿真数据集。仿真信号由两类典型无人机业务分量构成：宽带图传链路和跳频控制链路。通过对链路的载频占用、带宽尺度、时域持续特征及功率水平等进行参数化配置，可覆盖多种实际工作状态下的时频表现。

图9给出了四种典型时频样例，用于说明复合无人机射频信号在时频平面上的主要形态差异。各样例均由宽带图传链路与跳频控制链路叠加形成，

其中,连续条带状或块状能量区域对应宽带图传链路,反映其较大的瞬时带宽和较强的时域持续性;离散小能量簇对应跳频控制链路,体现其在频率维上的离散占用和时域上的间歇驻留特征。不同样例之间的差异主要体现在两个方面:一是宽带图传链路的带宽占用形态不同,表现为连续能量带的宽度、占空比及时间持续长度存在变化;二是跳频控制链路的跳频点分布不同,表现为离散能量簇的数量、频率落点及时间位置存在差异。上述样例表明,数据集中同时覆盖了不同图传带宽形态和不同跳频控制模式下的典型复合时频结构,可较好反映无人机射频业务在时频表示上的多样性。

所有复合信号经过统一的时频分析流程转换为幅度时频矩阵,作为后续检测网络的输入样本。为逼近真实电磁条件,仿真中叠加宽带高斯白噪声,并将总体信噪比控制在 $0\sim -20$ dB范围内,以2 dB为步长设置不同噪声强度,从而用于评估模型在噪声逐步增强情况下的检测鲁棒性。图10仅选取若干代表信噪比进行可视化对比。

在获得时频幅度矩阵后,对其中包含无人机业务信号的时频片段进行统一目标标注:将宽带图传块与跳频控制块共同视作“无人机射频目标”,采用单类别边界框标注其在时频平面上的空间范围。数据集共包含4400张时频图像,划分为训练集3520张、验证集440张与测试集440张。

此外,为进一步验证所提方法在真实采集射频信号上的适用性,本文引入DroneRFa公开无人机射频数据集进行补充实验。DroneRFa由软件无线

电设备采集无人机与遥控器之间的通信射频信号,覆盖915 MHz、2.4 GHz和5.8 GHz等ISM频段,原始文件包含RF0和RF1两路复基带通道,并提供无人机机型、距离和信号片段等标签信息。本文选取其中T0000~T1011编号样本,将T0001~T1011中的无人机通信信号统一作为单类别“无人机射频目标”进行时频图检测验证,T0000背景样本用于提供无目标或背景参照。需要说明的是,DroneRFa实验作为实采信号加噪退化条件下的补充验证实验,单独构建训练集、验证集和测试集。模型在DroneRFa加噪退化数据集上重新训练,在验证集上选择最优权重,并在独立测试集上进行评估。该实验主要用于验证所提方法在实采射频信号低信噪比退化条件下的适用性和检测鲁棒性。DroneRFa相关数据处理和加噪退化实验设置见4.6节。

3.2 实验环境与参数设置

实验所使用的有关硬件、软件及实验环境详细信息如表4所示。

实验训练批次为16、训练轮数为300;采用SGD优化器,初始学习率0.01、权重衰减0.0005,并使用余弦退火学习率策略;输入分辨率为 640×640 。此外,采用混合精度训练与数据增强以加速训练、降低显存占用并提升泛化能力。

3.3 评价指标

为全面评估不同检测模型及时频增强方法的性能,本文采用精度(Precision)、召回率(Recall)、平均精度(AP)、平均平均精度(mAP)等常用目标检测指标。同时,为刻画模型复杂度与计算开销,引入




图1 不同信噪比下的射频时频图

图9 典型复合射频时频样例

表 4

实验环境

环境	型号
操作系统	Windows 10
CPU	Intel Core i9-14900HX 2.20 GHz
GPU	NVIDIA GeForce RTX4090 16 GB
编译环境	Python 3.10.14
CUDA	12.1
深度学习框架	PyTorch 2.2.2

参数量(Params)和浮点运算量(GFLOPs)作为补充指标。

在二分类(前景/背景)检测任务中,以真正样本数记为 TP,误检数记为 FP,漏检数记为 FN,则精度和召回率分别定义为

$$Precision = \frac{TP}{TP + FP}, Recall = \frac{TP}{TP + FN} \quad (14)$$

在不同置信度阈值下得到的一组(Precision, Recall)组成 P - R 曲线,其下方面积即为平均精度 AP。对所有样本按 IoU 阈值 0.5 计算得到的 AP 记为 AP₅₀,对 IoU 阈值从 0.5 到 0.95 以 0.05 为步长取均值得到 AP_{50:95},本文分别以 mAP@0.5 和 mAP@0.5:0.95 作为主要检测精度指标。

参数量 (Params) 用于表征模型存储规模,浮点运算量 (GFLOPs) 用于量化单次前向推理所需的浮点运算次数,二者共同反映模型在资源受限平台上的部署代价。

后续实验将基于上述数据集与评价指标,对比分析 MEDE 增强前后不同 YOLO 系列轻量模型及 RF-YOLO-Lite 的检测性能,并通过消融实验验证各结构模块与时频增强策略的有效性。

4 实验结果分析

为降低单次随机生成样本对实验结论的影响,本文仿真实验均采用相同的数据生成规则、参数分布和标注方式重复构建实验数据集。不同实验小节根据验证目标分别生成对应的数据集,并在每组实验内部保持相同的数据划分、训练参数、测试集和评价指标。具体而言,4.1 节用于比较不同时频增强方法,4.3 节用于比较不同检测网络结构,4.4 节用于分析 RF-YOLO-Lite 各模块的消融贡献。由于表 5、表 7 和表 8 对应不同的独立生成数据集,跨表之间同一模型的绝对指标可能存在小幅波动,因

此本文主要依据各表内部的相对性能变化分析对应方法或模块的有效性,不直接进行跨表绝对数值比较。

4.1 MEDE 的检测性能评估

为验证所提多尺度能量密度引导时频增强 (MEDE) 方法的有效性,本文在不改变检测网络结构的前提下,以 YOLOv11n 为统一检测模型,对原始时频图、MEDE 增强时频图以及两类典型时频增强/去噪方法进行对比实验。对比方法包括小波去噪和高斯滤波。其中,小波去噪主要通过多尺度分解与阈值抑制降低噪声分量,高斯滤波则通过局部平滑抑制随机噪声。所有输入样本均采用相同训练配置和评价指标,以保证不同增强方法之间的公平比较。实验结果如表 5 所示。

表 5 增强/原始时频图上的检测性能比较

方法	Precision/%	Recall/%	mAP@0.5/%	mAP@0.5:0.95/%
原始时频图	92.55	78.07	86.59	66.43
MEDE	94.77	91.05	96.05	76.49
小波去噪	94.53	87.09	94.41	76.03
高斯滤波	94.19	79.33	87.95	68.10

由表 5 可见,相较于原始时频图,三种增强/去噪方法均能够在一定程度上提升检测性能,说明前端时频图处理有助于改善低信噪比条件下目标与背景的可分性。在本组增强方法对比实验中,MEDE 的综合性能最优, Precision、Recall、mAP@0.5 和 mAP@0.5:0.95 分别达到 94.77%、91.05%、96.05% 和 76.49%。与原始时频图相比,MEDE 的 Recall 提升 12.98 个百分点, mAP@0.5 提升 9.46 个百分点, mAP@0.5:0.95 提升 10.06 个百分点,表明其对弱目标漏检和定位不稳定问题具有明

显改善作用。

与小波去噪和高斯滤波相比, MEDE 的优势主要体现在目标区域的选择性增强。小波去噪能够通过多尺度分解抑制部分噪声, 因此性能明显优于原始时频图; 但其主要依据幅值分解和阈值策略进行处理, 对无人机射频目标的局部能量聚集性和连通域结构缺乏显式建模。高斯滤波能够平滑随机噪声, 但也可能模糊窄带谱线、短时跳频片段和局部能量边界。相比之下, MEDE 通过自适应前景掩膜、多尺度局部能量密度估计和连通域内部性权重, 对疑似目标区域施加选择性非线性增益, 因此能够在增强弱目标显著性的同时减少背景噪声同步放大。

图 11 进一步给出了不同信噪比条件下各方法的检测结果。总体来看, 随着信噪比从 -20 dB 提升至 0 dB, 各方法性能均逐步提高, 并在中高信噪比区间趋于饱和; 不同方法之间的差异主要集中在 $-20 \sim -16$ dB 的低信噪比区间。以 $\text{mAP}@0.5$ 为例, 在 -20 dB、 -18 dB 和 -16 dB 条件下, 原始时频图分别为 38.86% 、 53.84% 和 78.11% , MEDE 则分别提升至 63.90% 、 89.94% 和 97.67% , 明显优于原始时频图和小波去噪结果。说明 MEDE 的主要作用集中在强噪声背景下的弱目标增强阶段。

综上, MEDE 相较于原始时频图、小波去噪和高斯滤波均表现出更好的综合检测性能。其优势来自前景自适应筛选、多尺度能量聚集建模和内部性约束三者的共同作用, 能够有效提升低信噪比条件下无人机射频弱目标的可分辨性, 为后续检测网络提供更稳定的时频输入。







图 11 增强/原始时频图在不同信噪比下的实验结果

4.2 MEDE 参数敏感性分析

为进一步分析 MEDE 关键参数对增强效果的影响, 本文采用单因素变量法进行参数敏感性实验。实验中以 YOLOv11n 作为固定检测器, 保持数据划分、训练轮数、优化器、输入尺寸和测试阈值不变, 每次仅改变一个核心参数, 其余参数保持表 1 中的默认设置。考虑到多尺度核 $K^{(l)}$ 、内部性

融合权重 α 、连通域面积阈值 T_{area} 和形态学结构元素半径 r 主要用于保持局部统计和掩膜净化过程的结构稳定性,本文不对其逐一展开敏感性实验,而重点考察分位数门限 q 、动态范围 D 、增益上限 G_{max} 以及非线性指数 γ 对检测性能的影响。评价指标包括 Precision、Recall、mAP@0.5 和 mAP@0.5:0.95。

由表 6 可见,在合理参数范围内,MEDE 的检测性能整体波动较小,说明该方法对关键参数变化表现出较好的稳定性。所有参数组合下, mAP@0.5 基本保持在 0.957~0.965 之间,最大波动仅为 0.008; Recall 保持在 0.899~0.917 之间,整体变化幅度较小。这表明 MEDE 的性能提升并非依赖某一组精细调节的超参数获得,而是在较宽参数范围内均能保持稳定的增强效果。

对于分位数门限 q ,当 q 从 0.85 增大到 0.95 时, mAP@0.5 仅在 0.957~0.962 之间变化,整体较为稳定。其中, $q = 0.90$ 时 Recall 达到最高值 0.917,说明该设置能够保留更多低信噪比条件下的弱目标响应;当 q 进一步增大至 0.95 时, Recall 下降至 0.899,表明过高的分位数门限会使前景掩膜过于保守,部分弱小跳频片段和低能量目标边缘可能被漏选。因此,本文选取 $q = 0.90$ 作为默认分位数门限,以在弱目标保留和噪声抑制之间取得平衡。

对于动态范围 D ,当 D 在 40~70 dB 范围内变化时, mAP@0.5 保持在 0.958~0.962 之间,说明 MEDE 对动态范围参数具有较好的鲁棒性。其中, $D = 60$ dB 时 Recall 和 mAP@0.5 均达到最高值,分别为 0.917 和 0.962。较小的 D 会压缩低能量弱目标纹理,较大的 D 则会保留更多背景噪声和宽带干扰响应。综合考虑弱目标检出能力和整体检测精度,本文将 $D = 60$ dB 作为默认动态范围。

对于增益上限 G_{max} ,当 $G_{max} = 24$ dB 时 Precision 和 mAP@0.5 略高,说明较低增益有助于减少误检;当 $G_{max} = 32$ dB 时 Recall 达到最高值 0.917,说明适当提高增益能够增强弱目标显著性并降低漏检;当 G_{max} 进一步增大至 40 dB 时, Recall 和 mAP@0.5 反而下降,说明过强增强可能同步放大边缘噪声和干扰纹理,影响检测稳定性。因此,本文选择 $[G_{min}, G_{max}] = [8, 32]$ dB 作为默认增益区间,以兼顾弱目标召回率和整体检测性能。

对于非线性指数 γ ,实验结果显示, $\gamma = 1.0$ 时

Precision、mAP@0.5 和 mAP@0.5:0.95 较高,说明线性增益映射有利于获得较好的综合定位性能;而 $\gamma = 1.2$ 时 Recall 达到最高值 0.917,更有利于低信噪比弱目标检出。考虑到本文主要针对复杂频谱与低信噪比条件下无人机射频目标易漏检的问题,参数选择更侧重弱目标召回能力。因此,本文采用 $\gamma = 1.2$ 作为默认非线性指数。

表 6 MEDE 关键参数敏感性分析

参数	取值	Precision	Recall	mAP@0.5	mAP@0.5:0.95
q	0.85	0.952	0.912	0.961	0.762
	0.90	0.948	0.917	0.962	0.752
	0.93	0.947	0.908	0.961	0.779
	0.95	0.945	0.899	0.957	0.772
D	40	0.950	0.912	0.960	0.768
	50	0.945	0.908	0.958	0.762
	60	0.948	0.917	0.962	0.752
	70	0.951	0.907	0.961	0.764
G_{max}	24	0.955	0.912	0.964	0.767
	32	0.948	0.917	0.962	0.752
	40	0.952	0.909	0.959	0.771
γ	0.8	0.939	0.916	0.962	0.766
	1.0	0.952	0.914	0.965	0.769
	1.2	0.948	0.917	0.962	0.752
	1.5	0.946	0.912	0.960	0.768

综上,MEDE 在不同关键参数设置下均保持较稳定的检测性能,说明该方法具有较好的参数鲁棒性。本文最终采用 $q = 0.90$ 、 $D = 60$ dB、 $[G_{min}, G_{max}] = [8, 32]$ dB 和 $\gamma = 1.2$ 作为默认参数。所有 SNR 条件下均使用同一组参数,不针对不同信噪比样本进行单独调参,从而保证实验设置的一致性和方法的可复现性。

4.3 模型对比实验

在统一数据集与训练配置下,选取 YOLOv5n、YOLOv8n、YOLOv10n、YOLOv11n、YOLOv12n 等多种轻量化目标检测模型与 RF-YOLO-Lite 进行对比,结果如表 7 所示。同时,为增强对比实验的任务针对性,进一步引入面向射频时频图检测任务的 DFN-YOLO 作为专用模型对比方法。表中同时给出了参数量、GFLOPs、batch size = 1 条件下的

推理速度 (FPS) 以及 Precision、Recall 和 mAP@0.5 等指标, 用于综合评估模型的检测性能、复杂度和实时性。

从检测性能看, RF-YOLO-Lite 的综合表现最好, 其 Precision、Recall 和 mAP@0.5 分别达到 98.52%、89.59% 和 94.85%。与基线模型 YOLOv11n 相比, Precision 提升 2.19 个百分点, Recall 提升 3.84 个百分点, mAP@0.5 提升 1.38 个百分点, 说明所提网络在无人机射频时频图检测任务中具有更强的小目标检出能力和整体检测性能。

从模型复杂度看, RF-YOLO-Lite 的参数量仅为 1.39×10^6 , GFLOPs 为 5.4, 均为对比模型中最低。相较于 YOLOv11n, 其参数量下降约 46%, GFLOPs 下降约 14%; 相较于 YOLOv5n、YOLOv8n 等轻量模型, 也表现出更小的模型规模和更低的理论计算开销。这表明, 通过检测尺度重构以及骨干、颈部和检测头的协同轻量化设计, 模型复杂度得到了有效控制。

与射频时频图检测专用模型 DFN-YOLO 相比, RF-YOLO-Lite 的参数量由 3.08×10^6 降低至 1.39×10^6 , GFLOPs 由 8.1 降低至 5.4, FPS 由 200.10 帧/s 提升至 235.75 帧/s; 同时, Precision、Recall 和 mAP@0.5 也分别由 96.41%、85.65% 和 93.46% 提升至 98.52%、89.59% 和 94.85%。这说明 RF-YOLO-Lite 不仅相较通用轻量检测模型具有更优综合性能, 在面向射频时频图检测的专用模型对比中也表现出更好的精度与复杂度平衡。

从实际推理速度看, RF-YOLO-Lite 在当前实验平台上的 FPS 为 235.75 帧/s, 略高于 YOLOv11n 的 230.12 帧/s, 也高于其余对比模型。按单帧延迟折算, 其平均推理时间约为 4.24 ms/帧, 与 YOLOv11n 相比具有一定优势。这表明, 所提模型在

当前实验平台上具有较高的推理速度, 模型复杂度下降在一定程度上转化为了实际推理效率提升; 但在具体边缘硬件上的部署表现仍需进一步验证。

为比较噪声鲁棒性, 选取参数量与计算量同量级的 YOLOv5n、YOLOv8n、YOLOv11n 与 RF-YOLO-Lite, 统计其在不同 SNR 下的 mAP@0.5。结果如图 12 所示, 在 $-20 \sim -16$ dB 的极低 SNR 区间, RF-YOLO-Lite 相对其他轻量 YOLO 模型保持约 1 个百分点以上的 mAP 优势; 当 $\text{SNR} \geq -14$ dB 时, 各模型性能趋于饱和, mAP@0.5 接近 100%, 差异收敛。因此, 在总体复杂度相当条件下, RF-YOLO-Lite 在低信噪比场景表现出更强的噪声鲁棒性。




图 12 不同模型在不同信噪比下的实验结果

4.4 模型消融实验

为定量分析各结构改进对检测性能、模型复杂度及实际推理效率的影响, 本文以 YOLOv11n 为基线模型, 依次引入 P2 检测层、P5 检测头裁剪、Ghost 模块、SlimNeck 以及 Detect_LSDECD, 消融

表 7

模型对比实验结果

模型	参数量	GFLOPs	FPS / (帧 · s ⁻¹)	Precision/%	Recall/%	mAP@0.5/%
YOLOv5n	2.50×10^6	7.1	209.73	96.08	87.48	93.39
YOLOv8n	3.00×10^6	8.1	220.64	96.19	87.87	93.81
YOLOv10n	2.26×10^6	6.5	226.91	96.13	85.03	93.11
YOLOv11n	2.58×10^6	6.3	230.12	96.33	85.75	93.47
YOLOv12n	2.55×10^6	6.3	162.44	95.72	85.35	92.71
DFN-YOLO	3.08×10^6	8.1	200.10	96.41	85.65	93.46
RF-YOLO-Lite	1.39×10^6	5.4	235.75	98.52	89.59	94.85

实验结果如表 8 所示。

由表 8 可见, 引入 P2 检测层后, $\text{mAP}@0.5$ 由 93.47% 提升至 94.91%, $\text{mAP}@0.5:0.95$ 由 77.75% 提升至 80.74%, 说明高分辨率 P2 分支能够增强网络对窄带谱线、跳频片段和局部弱能量块等小尺度目标的感知能力。但与此同时, GFLOPs 由 6.3 增加至 10.3, FPS 由 230.12 帧/s 降至 190.59 帧/s, 表明高分辨率检测分支会带来明显的计算和访存开销。

在保留 P2 检测层的基础上裁剪 P5 直接检测分支后, 参数量由 2.67×10^6 降至 1.94×10^6 , GFLOPs 由 10.3 降至 9.8, FPS 由 190.59 帧/s 提升至 201.92 帧/s, 而 $\text{mAP}@0.5$ 和 $\text{mAP}@0.5:0.95$ 基本保持稳定。这说明在本文数据集中, 目标主要表现为小尺度和中小尺度时频结构, P5 低分辨率检测头的直接检测贡献有限。保留 P5 高层语义特征参与融合、但取消其直接检测输出, 能够在基本不损失精度的情况下降低大尺度预测分支的冗余开销。

进一步引入 Ghost 模块后, 参数量由 1.94×10^6 降至 1.62×10^6 , GFLOPs 由 9.8 降至 9.1, 说明 Ghost 模块能够有效降低骨干网络的参数量和理论计算量。但此时 FPS 由 201.92 帧/s 降至 187.36 帧/s, 并未随 GFLOPs 下降而提升。其原因在于, Ghost 模块内部包含轻量线性变换、特征拼接和通道组合等操作。在 RTX4090 这类高端 GPU 上, 标准卷积通常具有高度优化的 cuDNN 实现, 而小算子、深度可分离卷积和 concat 操作可能带来额外的访存和调度开销。因此, Ghost 的主要作用应理解为压缩模型参数量和理论计算量, 而非在所有硬件平台上必然提升实际 FPS。

在 Ghost 模块基础上引入 SlimNeck 后, GFLOPs 进一步降至 8.6, FPS 恢复至 201.84 帧/s,

$\text{mAP}@0.5$ 和 $\text{mAP}@0.5:0.95$ 分别为 94.90% 和 80.33%。这说明 SlimNeck 对多尺度特征融合阶段的计算压缩较为有效, 能够在保持跨尺度特征表达能力的同时减少 Neck 中的冗余卷积与访存开销。

最后, 将检测头替换为 Detect_LSDECD 后, 参数量进一步降至 1.39×10^6 , GFLOPs 降至 5.4, FPS 提升至 235.75 帧/s。该结果表明, 多尺度检测头中的重复分类和回归分支也是影响模型复杂度和推理速度的重要来源。Detect_LSDECD 通过通道统一、共享细节增强卷积和轻量解耦预测, 减少了 P2、P3 和 P4 多尺度检测头中的重复计算, 使最终模型获得最低参数量、最低 GFLOPs 和最高 FPS。

综合来看, 各模块对精度和效率的影响并不完全一致。P2 检测层主要提升弱小目标检测性能, 但会增加计算开销; P5 检测头裁剪能够减少任务相关性较低的大尺度预测冗余; Ghost 模块降低参数量和理论计算量, 但在高端 GPU 上可能受算子调度与访存影响导致 FPS 下降; SlimNeck 和 Detect_LSDECD 则进一步压缩特征融合和预测端开销, 使最终模型在保持较高检测精度的同时获得更优的参数量、计算量和推理速度折中。

4.5 时频增强与轻量结构的协同效果

为进一步分析时频增强与轻量化检测网络之间的协同作用, 本文比较 YOLOv11n+原始时频图、YOLOv11n+增强时频图、RF-YOLO-Lite+原始时频图和 RF-YOLO-Lite+增强时频图四种组合在不同信噪比条件下的检测结果, 如图 13 所示。

总体来看, 随着信噪比提高, 四种组合的 Precision、Recall、 $\text{mAP}@0.5$ 和 $\text{mAP}@0.5:0.95$ 均逐步提升, 并在中高信噪比区间趋于饱和。在低信噪比区间, 各方法之间的性能差异更为明显, 说明前端增强和网络结构改进主要作用于强噪声背景下的弱

表 8

消融实验结果

P2	P5	Ghost	SlimNeck	Detect_LSDECD	参数量	GFLOPs	FPS / (帧 · s ⁻¹)	mAP@0.5/%	mAP@0.5:0.95/%
					2.58×10^6	6.3	230.12	93.47	77.75
√					2.67×10^6	10.3	190.59	94.91	80.74
√	√				1.94×10^6	9.8	201.92	94.93	80.81
√	√	√			1.62×10^6	9.1	187.36	94.78	79.74
√	√	√	√		1.63×10^6	8.6	201.84	94.90	80.33
√	√	√	√	√	1.39×10^6	5.4	235.75	94.85	79.86

目标检测场景。

从单因素作用看,在相同检测网络条件下,MEDE 增强时频图的检测结果整体优于原始时频图,说明前端增强能够提升弱目标纹理的可分辨性;在相同输入条件下,RF-YOLO-Lite 整体优于 YOLOv11n,说明尺度重构和轻量化结构能够增强网络对小尺度时频目标的表征能力。二者联合使用时,RF-YOLO-Lite+增强时频图在低信噪比区间取得更优结果,表明前端增强与后端检测网络之间具有较好的互补性。

需要指出的是,虽然联合方法在极低信噪比条件下取得了相对更好的结果,但其绝对性能仍然有限。例如在-20 dB 条件下,最优组合仍存在一定漏检,说明当目标能量被强噪声严重淹没时,时频增强和检测网络仍难以完全恢复弱目标结构。因此,本文方法更准确的结论是:在低信噪比范围内能够有效改善弱目标检测性能,但并未完全突破极端噪声条件下的检测失效边界。







图 13 四种组合在不同信噪比下的实验结果

图 15 给出了同一样本在-18 dB 条件下四种方法的检测可视化结果,其中图 15 (a)为 0 dB 参考图及真实边界框,用于说明目标在高信噪比条件下的原始时频位置和结构形态。由图 15 (b)-(e)可见,在低信噪比背景下,上方跳频控制链路对应的离散弱目标以及下方宽带图传链路边界均受到明显噪声干扰,不同方法在漏检和误检表现上存在差异。

其中, YOLOv11n+原始时频图的检测结果如图 15 (b)所示,可见其在上方离散弱目标区域存在较明显的漏检现象;采用 RF-YOLO-Lite 后,如图 15 (c)所示,部分弱目标得到了补充检测。与原始时频图相比,增强时频图输入能够进一步改善弱纹理的可分辨性, YOLOv11n+增强时频图如图 15 (d)所示,漏检目标数量有所减少。综合结构改进与增强输入后, RF-YOLO-Lite+增强时频图的结果如图 15 (e)所示,其对离散弱目标和连续占用带边界的检测更完整,整体漏检现象相对较少。

该可视化结果与前述定量分析基本一致,说明时频增强主要改善了低信噪比条件下弱目标纹理的

可分辨性, 而 RF-YOLO-Lite 则进一步增强了对小尺度时频结构的表征能力。二者联合使用时, 对低信噪比场景中的目标检出更为有利; 但从图中仍可看出, 在较强噪声背景下, 部分弱目标响应依旧较弱, 说明该方法在极低信噪比条件下仍存在一定失效边界。

4.6 基于 DroneRFa 实采数据集的鲁棒性验证

为进一步验证所提方法在公开实采无人机射频数据上的适用性, 本文补充引入 DroneRFa 数据集开展低信噪比退化实验。DroneRFa 数据集由软件无线电设备采集真实无人机与遥控器之间的通信射频信号, 能够反映实际信道、设备响应、环境噪声、频段切换和背景干扰等因素。与前文构建的可控仿真数据不同, DroneRFa 的信号主体来自真实采集环境, 因此可用于补充评估所提方法在实采射频信号上的适用性和鲁棒性。

本文选取 DroneRFa 中 T0000~T1011 编号对应的数据文件进行实验。其中, T0000 为背景参照信号, T0001~T1011 为无人机射频信号样本, 覆盖 DJI Phantom 3、DJI Phantom 4 Pro、DJI MATRICE 200、DJI MATRICE 100、DJI Air 2S、DJI Mini 3 Pro、DJI Inspire 2、DJI Mavic Pro、DJI Mini 2、DJI Mavic 3 和 DJI MATRICE 300 等机型。考虑到本文任务为无人机射频目标区域检测, 而非无人机型号识别, 因此所有无人机机型统一标注为单类别“无人机射频目标”, 背景样本用于提供无目标参照和复杂背景干扰样本。

DroneRFa 原始文件为 .mat 格式, 每个文件包含 RF0_I、RF0_Q、RF1_I 和 RF1_Q 四个通道。本文分别将 RF0_I 与 RF0_Q 组合为 RF0 复基带信号, 将 RF1_I 与 RF1_Q 组合为 RF1 复基带信号。根据

DroneRFa 数据集的频段标注规则, S0000~S0111 主要对应初始通信频段, 本文保留 RF0 通道生成时频图; S1000~S1111 对应设备支持情况下的频段切换样本, 本文同时保留 RF0 与 RF1 通道生成时频图, 以覆盖 2.4 GHz 和 5.8 GHz 频段下的无人机通信信号。

在时频图生成阶段, 采样率设置为 100 MS/s, RF0 通道中心频率设置为 2.44 GHz, RF1 通道中心频率设置为 5.8 GHz。考虑到 DroneRFa 数据采用“采-存-采-存”的采集模式, 且每 10 兆采样点内数据连续, 本文以 10 兆采样点作为连续处理单元, 并将其切分为 0.1 s 的复基带片段。每个片段经 STFT 转换为时频图, 窗函数采用 Hamming 窗, 窗长为 2048 点, 帧重叠率为 75%, FFT 点数为 4096。上述 STFT 参数与本文仿真数据集保持一致, 以保证仿真数据和实采数据在时频表示尺度上的可比性。

由于原始 DroneRFa 数据集并非直接面向目标检测任务提供边界框标注, 本文在生成 STFT 时频图后, 对无人机射频信号占用区域进行单类别边界框标注。标注对象包括跳频控制链路对应的离散能量簇、图传链路对应的连续能量块以及其他可见无人机通信占用区域。标注时将同一时频图中的所有无人机通信占用区域统一视作“无人机射频目标”, 不区分具体机型和通信链路类型。

为评估不同噪声强度下的检测鲁棒性, 本文在 DroneRFa 原始复基带信号上额外叠加复高斯白噪声, 构建加噪退化数据集。信噪比范围设置为 -30 ~ 0 dB, 步长为 2 dB。需要说明的是, 该实验并非纯仿真数据实验, 其信号主体来自 DroneRFa 实采采集数据, 人工加噪仅用于控制噪声强度, 从而分




图 1 (a) 为 0 dB 参考图及真实边界框; (b-e) 为同一样本在 -18 dB 条件下的检测结果, 分别对应 YOLOv11n+ 原始时频图、RF-YOLO-Lite+ 原始时频图、YOLOv11n+ 增强时频图和 RF-YOLO-Lite+ 增强时频图。图中蓝色实线框表示正确检测结果 (TP), 红色实线框表示漏检目标对应的真值位置 (FN), 黑色实线框表示误检目标 (FP)。

析所提方法在真实信号低信噪比退化条件下的检测能力。为避免数据泄漏,数据划分在加噪之前完成,同一原始.mat文件或同一连续片段生成的不同 SNR 样本仅出现在训练集、验证集或测试集中的一个子集中。最终构建的 DroneRFa 加噪退化检测数据集共包含 19303 张时频图样本,并按照 8:1:1 的比例划分为训练集、验证集和测试集。其中,训练集 15442 张,验证集 1930 张,测试集 1931 张。

在模型训练与测试设置方面, DroneRFa 加噪退化实验采用与前述实验一致的训练流程。具体而言, YOLOv11n 和 RF-YOLO-Lite 均在 DroneRFa 加噪退化数据集的训练集上重新训练,并通过验证集选择最优模型权重,最终在独立测试集上统计 Precision、Recall、mAP@0.5 和 mAP@0.5:0.95。与仿真数据训练后直接测试 DroneRFa 数据的跨数据集评估不同,本文 DroneRFa 实验主要考察同一实采数据域内不同信噪比退化条件下的检测表现,实验结果主要用于说明所提方法在实采射频信号加噪退化条件下的检测鲁棒性。

对于复基带信号 $x(n)$, 其平均信号功率定义为

$$P_s = \frac{1}{N} \sum_{n=1}^N |x(n)|^2 \quad (15)$$

在给定信噪比 SNR_{dB} 下, 噪声功率为

$$P_n = \frac{P_s}{10^{\text{SNR}_{dB}/10}} \quad (16)$$

对于复信号, 加入的复高斯白噪声为

$$w(n) = \sqrt{\frac{P_n}{2}} (w_I(n) + jw_Q(n)) \quad (17)$$

其中, $w_I(n)$ 和 $w_Q(n)$ 为相互独立的标准高斯随机变量。最终加噪信号表示为

$$x_{\text{noisy}}(n) = x(n) + w(n) \quad (18)$$

图 16 给出了同一 DroneRFa 实采信号片段在不同加噪 SNR 条件下的时频图样例。第一行为加噪后的原始时频图, 第二行为对应的 MEDE 增强时频图。各子图采用相同 STFT 参数和统一显示范围。随着 SNR 由 0 dB 降低至 -30 dB, 目标能量结构逐渐被噪声淹没; 经 MEDE 处理后, 弱目标区域的局部能量聚集结构得到一定增强, 但在极低 SNR 条件下仍存在部分目标结构难以恢复的情况。

在 DroneRFa 加噪退化数据集上, 本文分别比较 YOLOv11n+原始时频图、YOLOv11n+MEDE 增强时频图、RF-YOLO-Lite+原始时频图以及 RF-YOLO-Lite+MEDE 增强时频图四种组合, 实验结果如表 9 所示。

表 9 DroneRFa 加噪退化数据集上的检测性能比较

方法组合	Precision/%	Recall/%	mAP@0.5/%	mAP@0.5:0.95/%
YOLOv11n + 原始时频图	90.91	55.44	65.14	52.42
YOLOv11n + MEDE 增强时频图	93.42	64.26	73.59	61.76
RF-YOLO-Lite + 原始时频图	93.23	62.56	72.42	57.45
RF-YOLO-Lite + MEDE 增强时频图	95.09	78.16	85.72	71.77





图 1 DroneRFa 实采信号在不同加噪 SNR 条件下的时频图样例

由表 9 可见,在 DroneRFa 加噪退化数据集上,YOLOv11n+ 原始时频图的 Recall 仅为 55.44%,mAP@0.5 为 65.14%,说明在强噪声退化条件下,直接基于原始时频图进行检测时,弱目标容易被噪声背景淹没,漏检问题较为明显。引入 MEDE 后,YOLOv11n 的 Precision、Recall、mAP@0.5 和 mAP@0.5:0.95 分别提升至 93.42%、64.26%、73.59% 和 61.76%,相比原始时频图输入分别提升 2.51、8.82、8.45 和 9.34 个百分点。这表明 MEDE 能够增强真实射频时频图中弱目标纹理的显著性,尤其有助于提升低信噪比条件下的目标召回能力。


在相同原始时频图输入条件下,RF-YOLO-Lite 的 Recall 和 mAP@0.5 分别达到 62.56% 和 72.42%,相比 YOLOv11n 分别提升 7.12 和 7.28 个百分点,说明所提出的尺度重构和轻量化检测结构不仅适用于仿真数据,在 DroneRFa 实采加噪数据上同样能够提升无人机射频目标检测能力。进一步地,RF-YOLO-Lite 与 MEDE 联合使用时取得最优结果,Precision、Recall、mAP@0.5 和 mAP@0.5:0.95 分别达到 95.09%、78.16%、85.72% 和 71.77%。与 YOLOv11n+ 原始时频图相比,联合方法的 Recall 提升 22.72 个百分点,mAP@0.5 提升 20.58 个百分点,mAP@0.5:0.95 提升 19.35 个百分点。

上述结果表明,在基于 DroneRFa 实采信号构造的低信噪比退化场景下,MEDE 与 RF-YOLO-Lite 均能独立提升检测性能,二者联合时效果最优。这说明前端时频增强能够改善低信噪比条件下弱目标纹理的可分辨性,后端轻量化检测网络能够进一步提升小尺度时频结构的表征能力,二者具有较好的互补作用。与前文仿真数据集实验相比,DroneRFa 实采加噪退化实验进一步说明了所提方法在实采射频信号低信噪比退化条件下的适用性和检测鲁棒性。


为进一步分析不同噪声强度下各方法的鲁棒性,本文统计了四种组合在 DroneRFa 加噪退化数据集上的分 SNR 检测结果。随着 SNR 从 -30 dB 提升至 0 dB,各方法的 Recall、mAP@0.5 和 mAP@0.5:0.95 均整体上升,说明噪声强度降低后目标时频结构更加清晰,检测难度逐渐下降。



(a) 精确率



(b) 召回率



(c) mAP@0.5




图 16 DroneRFa 加噪退化数据集上不同方法在不同信噪比下检测结果

在极低 SNR 区间, 原始时频图输入下的检测性能下降较为明显。例如在 -30 dB 条件下, YOLOv11n+原始时频图的 $mAP@0.5$ 仅为 4.89%, RF-YOLO-Lite+原始时频图的 $mAP@0.5$ 也仅为 5.38%; 引入 MEDE 后, YOLOv11n 的 $mAP@0.5$ 提升至 28.64%, RF-YOLO-Lite 的 $mAP@0.5$ 提升至 32.78%。这表明在强噪声背景下, MEDE 能够有效增强弱目标时频纹理的显著性, 从而降低由噪声淹没导致的漏检。

从整体趋势看, MEDE 对低 SNR 区间的提升更为明显。在 -30~-22 dB 区间, YOLOv11n+MEDE 增强时频图的平均 $mAP@0.5$ 相比 YOLOv11n+原始时频图明显提升; RF-YOLO-Lite+MEDE 增强时频图也显著优于 RF-YOLO-Lite+原始时频图。这说明 MEDE 的主要作用集中在强噪声条件下的弱目标增强, 而在中高 SNR 条件下, 目标结构本身已经较为清晰, 增强带来的边际收益逐渐减小。

同时, 在相同输入条件下, RF-YOLO-Lite 整体优于 YOLOv11n, 尤其在中低 SNR 区间表现更加稳定。RF-YOLO-Lite+MEDE 增强时频图在各 SNR 条件下总体取得最优结果, 在 0 dB 条件下 $mAP@0.5$ 达到 99.40%, $mAP@0.5:0.95$ 达到 92.56%; 在 -20 dB 条件下 $mAP@0.5$ 仍达到 83.88%, 明显高于其他组合。上述结果说明, 前端 MEDE 时频增强与后端 RF-YOLO-Lite 轻量检测网络具有较好的互补作用, 能够在 DroneRFa 实采信号退化条件下提升低信噪比无人机射频目标检测性能。

5 结束语

针对复杂频谱与低信噪比条件下无人机射频信号在时频图上弱能量结构易被噪声与干扰淹没、检测易漏检且难兼顾实时性的难题, 本文构建了“时频增强—轻量检测”一体化框架。前端提出多尺度能量密度引导时频增强 (MEDE), 在 STFT 幅度谱基础上融合自适应前景掩膜、多尺度局部能量密度估计与连通域内部权重约束, 提升弱目标显著性并抑制边缘过增强与背景纹理干扰, 从而增强目标与背景的可分性。后端设计 RF-YOLO-Lite, 通过尺度重构与轻量特征生成等策略压缩冗余计算, 在保持检测精度的同时降低模型复杂度。实验结果表明, 该框架在仿真低信噪比场景下具有较稳定的检出能力, 并在基于 DroneRFa 实采复基带信号构建的加噪退化数据集上表现出较好的检测鲁棒性, 说明所提时频增强与轻量检测结构对实采射频信号低信噪比退化条件具有一定适用性; 其在具体边缘硬件上的实时部署效果仍有待进一步验证。

参考文献:

- [1] 吴一全, 童康. 基于深度学习的无人机航拍图像小目标检测研究进展[J]. 航空学报, 2025, 46(3): 181-207.
Wu Y Q, Tong K. Research progress of small target detection in UAV aerial images based on deep learning[J]. Acta Aeronautica et Astronautica Sinica, 2025, 46(3): 181-207.
- [2] 傅惠, 崔煜, 赵佳虹, 等. 低空无人机物流配送研究与应用综述[J]. 工业工程, 2025, 28(1): 9-21.
Fu H, Cui Y, Zhao J H, et al. A review of low-altitude UAV logistics distribution research and applications[J]. Industrial Engineering, 2025, 28(1): 9-21.
- [3] 吕斯宁, 肖川, 冯恒振, 等. 集群协同作战技术现状与战争应用综述[J]. 探测与控制学报, 2025, 47(3): 1-16.
Lv S N, Xiao C, Feng H Z, et al. Review of the current status and war applications of swarm cooperative combat technologies[J]. Journal of Detection and Control, 2025, 47(3): 1-16.
- [4] 王庆. 低空经济发展: 新兴安全风险与敏捷治理[J]. 科学学研究, 2025, 43(8): 1569-1578.
Wang Q. Development of the low-altitude economy: emerging security risks and agile governance[J]. Studies in Science of Science, 2025, 43(8): 1569-1578.
- [5] Wang C, Tian J, Cao J, et al. Deep learning-based UAV detection in pulse-Doppler radar[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 60: 1-12.
- [6] Huang M, Mi W, Wang Y. EDGS-YOLOv8: an improved YOLOv8 lightweight UAV detection model[J]. Drones, 2024, 8(7): 337.
- [7] Tejera-Berengue D, Zhu-Zhou F, Utrilla-Manso M, et al. Analysis of distance and environmental impact on UAV acoustic detection[J]. Electron-

- ics, 2024, 13(3): 643.
- [8] Alkhonaini A, Sheltami T, Mahmoud A, et al. UAV detection using reinforcement learning[J]. Sensors, 2024, 24(6): 1870.
- [9] Seidaliyeva U, Ilipbayeva L, Taissariyeva K, et al. Advances and challenges in drone detection and classification techniques: a state-of-the-art review[J]. Sensors, 2023, 24(1): 125.
- [10] 高锐. 复杂电磁环境下的信号检测技术研究[D]. 西安: 西安电子科技大学, 2015.
- Gao R. Research on signal detection technology in complex electromagnetic environments[D]. Xi'an: Xidian University, 2015.
- [11] Vagollari A, Schram V, Wicke W, et al. Joint detection and classification of RF signals using deep learning[C]//2021 IEEE 93rd Vehicular Technology Conference (VTC2021-Spring). Piscataway: IEEE Press, 2021: 1-7.
- [12] Anna T Q, Reese R D. YOLO for radio frequency signal classification [C]//2024 IEEE International Symposium on Dynamic Spectrum Access Networks. Piscataway: IEEE Press, 2024: 177-178.
- [13] Nguyen H N, Vomvas M, Vo-Huu T D, et al. WRIST: wideband, real-time, spectro-temporal RF identification system using deep learning[J]. IEEE Transactions on Mobile Computing, 2023, 23(2): 1550-1567.
- [14] Jiang K, Peng K, Feng Y, et al. DFN-YOLO: detecting narrowband signals in broadband spectrum[J]. Sensors, 2025, 25(13): 4206.
- [15] Delleji T, Slimeni F. RF-YOLO: a modified YOLO model for UAV detection and classification using RF spectrogram images[J]. Telecommunication Systems, 2025, 88(1): 33.
- [16] 俞宁宁, 毛盛健, 周成伟, 等. DroneRFa: 用于侦测低空无人机的规模无人机射频信号数据集[J]. 电子与信息学报, 2024, 46(4): 1147-1156.
- Yu N N, Mao S J, Zhou C W, et al. DroneRFa: a large-scale UAV RF signal dataset for detecting low-altitude UAVs[J]. Journal of Electronics & Information Technology, 2024, 46(4): 1147-1156.
- [17] Shi R, Yu X, Wang S, et al. RFUAV: a benchmark dataset for unmanned aerial vehicle detection and identification[EB/OL]. arXiv: 2503.09033, 2025[2026-07-18]. DOI: 10.48550/arXiv.2503.09033.
- [18] Kang X, Chen H, Chen G, et al. Optimal preprocessing for joint detection and classification of wireless communication signals in congested spectrum using computer vision methods[EB/OL]. arXiv: 2408.06545, 2024[2026-07-18]. DOI: 10.48550/arXiv.2408.06545.
- [19] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2016: 779-788.
- [20] Han K, Wang Y, Tian Q, et al. GhostNet: more features from cheap operations[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2020: 1580-1589.
- [21] Li H, Li J, Wei H, et al. Slim-neck by GSConv: a lightweight-design for real-time detector architectures[J]. Journal of Real-Time Image Processing, 2024, 21(3): 62.
- [22] 孙铁强, 洪兆志, 宋超, 等. 基于多尺度特征融合的轻量化绝缘子缺陷检测[J]. 激光与光电子学进展, 2025, 62(6): 136-147.
- Sun T Q, Hong Z Z, Song C, et al. Lightweight insulator defect detection based on multi-scale feature fusion[J]. Laser & Optoelectronics Progress, 2025, 62(6): 136-147.



王巍 (1980—), 男, 博士, 电磁空间安全全国重点实验室正高级工程师, 主要研究方向为网络安全、无线通信。



史众楷 (2002—), 男, 杭州电子科技大学硕士生, 主要研究方向为信号检测。



孙闽红 (1974—), 男, 博士, 杭州电子科技大学教授, 主要研究方向为信号处理、信息对抗、智能侦察与抗干扰。



杨少飞 (1994—), 男, 博士, 电磁空间安全全国重点实验室中级工程师, 主要研究方向为信号智能处理, 人工智能应用技术。



沈伟国 (1987—), 男, 电磁空间安全全国重点实验室正高级工程师, 主要研究方向为信号智能处理。