

文章编号:1671-6833(2025)05-0043-08

基于改进 YOLOv5s 干扰跳频信号调制识别

张海宾¹, 魏洪基¹, 王超², 向长波³, 杨明洋³, 李晓龙⁴

(1. 西安电子科技大学 杭州研究院, 浙江 杭州 311200; 2. 西安电子科技大学 通信工程学院, 陕西 西安 710126; 3. 中电科思仪科技有限公司, 山东 青岛 266555; 4. 北京控制与电子技术研究所, 北京 100038)

摘要: 复杂电磁环境中干扰信号会严重恶化跳频信号检测和识别性能, 为了解决传统的检测方法在实际应用中存在错检、漏检、误检、多检等问题, 通过对 YOLOv5s 网络进行改进, 提出一种基于时频图的信号检测和识别算法。首先, 构建了跳频信号+干扰信号组合模式的数据集, 包含 4 种不同跳频信号调制类型和 6 种不同干扰类型, 每个组合生成 300 个高分辨率时频图样本, 总计构建 7 200 组数据; 其次, 考虑到干扰和信号在时频图上拥有相似的特征, 而跳频信号频率会随时间不断跳变, 这使得信号附近的背景信息成为区分信号与干扰的关键特征, 提出利用语境分层模块对背景信息进行分级, 采用深度可分离卷积模块提取信号附近的背景信息, 利用门控聚合机制加权聚合背景信息和信号特征, 输出更具判别力的复合特征; 最后, 利用语境分层模块与门控聚合机制对 YOLOv5s 网络的主干网络部分进行改造, 得到改进的跳频信号检测器。仿真结果表明, 较传统 YOLOv5s 网络, 所提算法的召回率 R 提升 15.9 个百分点, 均值平均精度 $mAP@0.5:0.95$ 提升 8.9 个百分点, $F1$ 提升 9 个百分点, 错检、漏检等情况显著减少。

关键词: 跳频信号; 信号检测; 信号识别; 干扰信号; YOLOv5s

中图分类号: TN971 **文献标志码:** A **doi:** 10.13705/j.issn.1671-6833.2025.05.008

跳频通信技术作为一类关键抗截获、抗干扰技术, 因其通过宽频段内载波频率的快速跳变实现恶意干扰规避与侦听防御, 在现代军事通信系统中具有重要应用价值。然而, 跳频信号的时变载频特性显著增加了其检测与识别的技术难度, 这一挑战性课题已引起广泛关注。值得注意的是复杂电磁环境中的密集干扰信号(特指跳频信道内共存的多类型干扰源)会严重劣化信号检测性能, 这一现象在工业物联网、军事通信及雷达系统等应用场景中尤为突出。

现有跳频信号检测与识别方法可系统划分为基于特征工程的经典方法与基于深度学习的现代方法两类技术路线。前者主要依赖领域先验知识, 通过人工设计的时频特征提取实现调制类型识别。典型研究包括: 基于时频能量谱纹理特征捕捉信号频谱动态变化^[1]; 利用梯度方向直方图(histogram of oriented gradient, HOG)^[2]来提取时频图中的边缘和

方向特征; 构建双稀疏性特征表征模型进行调制识别^[3]。尽管这些方法在特定场景下表现良好, 但其性能受到特征工程质量的限制, 存在特征表征能力不足、环境适应性弱等缺陷。

随着人工智能与计算机视觉技术的突破性进展, 基于深度学习的自动特征提取方法已成为跳频信号识别领域的主流研究方向。该类方法通过时频分析技术(如时频特征提取、多时相星座图构建等)获取信号多维特征表征, 并利用深度神经网络实现特征的自适应提取与分类决策, 在复杂电磁环境中展现出显著的性能优势。现有研究已取得诸多进展, 例如基于 choi-williams 分布(choi-williams distribution, CWD)时频图谱构建与 YOLOv5 分类器集成的自动识别框架^[4]; Gabor 变换特征图与 YOLOv5 协同的跳频信号分类模型^[5]; 短时傅里叶变换(short time fourier transform, STFT)时频特征与单步检测器(single shot detector, SSD)融合的调制识别

收稿日期: 2025-02-20; 修订日期: 2025-04-11

基金项目: 国防基础科研计划资助(JCKY2021608B001)

作者简介: 张海宾(1981—), 男, 山东菏泽人, 西安电子科技大学教授, 博士, 博士生导师, 主要从事人工智能安全、工业互联网安全方面的研究, E-mail: hbzhang@mail.xidian.edu.cn。

通信作者: 王超(1985—), 男, 江苏徐州人, 西安电子科技大学副教授, 博士, 博士生导师, 主要从事 5G & 6G 无线网络及关键技术、物理层安全、隐蔽通信、深度学习及其在无线通信优化中的应用方面的研究, E-mail: chaowang@xidian.edu.cn。

引用本文: 张海宾, 魏洪基, 王超, 等. 基于改进 YOLOv5s 干扰跳频信号调制识别[J]. 郑州大学学报(工学版), 2025, 46(5): 43-50. (ZHANG H B, WEI H J, WANG C, et al. Modulation recognition of frequency hopping signal under interference based on improved YOLOv5s[J]. Journal of Zhengzhou University, 2025, 46(5): 43-50.)

系统研究^[6]等代表性成果,均验证了深度学习方法的有效性。深度学习方法凭借其自动特征学习机制与强泛化能力,已成为信号识别领域的研究前沿。其中,YOLOv5s网络作为轻量级目标检测模型,在检测效率与识别精度间实现了优化平衡,尤其适用于复杂频谱环境下的跳频信号识别任务。其多维度特征提取能力可有效提高干扰场景下的识别鲁棒性。基于此,本研究提出基于STFT时频YOLOv5s网络架构,旨在构建面向复杂干扰环境的跳频信号高效检测与识别系统。本文的核心创新点体现在以下两个方面:

(1)为了能够准确区分干扰与信号,增大网络视野,采用语境分层与门控聚合机制来优化YOLOv5s网络的主干网络部分,提升网络对信号和背景特征的融合能力,改善信号识别率。语境分层包含多个深度可分离卷积(depth-wise separable convolutions, DSC)^[7],用来获取分级的上下文信息,在维持精度的同时降低参数量,提升检测速度;而门控聚合则是通过对不同层次的特征进行加权融合,提高网络对重要信息的学习能力,从而显著提升识别精度。

(2)本文采用蒙特卡罗仿真,验证了改进后的YOLOv5s网络性能较之传统的YOLOv5网络,其综合 $mAP@0.5:0.95$ 提升8.9个百分点,识别精确率 P 提升0.5个百分点,召回率 R 提升15.9个百分点, $F1$ 提升9个百分点,显著提升了复杂频谱环境中跳频信号的检测和识别性能。

1 干扰环境中基于YOLOv5s网络的信号检测与识别

1.1 YOLOv5网络

当前,目标检测的主流方法大致分为两种:以Fast R-CNN^[8]和Faster R-CNN^[9]网络为代表的两阶段目标检测,以及以YOLO^[10]和SSD^[11]为代表的单阶段目标检测。由于两阶段目标检测在进行图像识别时需要先选出候选区域,再对选出的候选区域进行调整分类,这就使得双阶段比单阶段的检测精度高,但同时检测速度大打折扣。随着YOLO网络的不断更新,单阶段目标检测已能够在保证较高检测速度的同时兼顾良好的检测精度。YOLOv5网络结构如图1所示。

YOLOv5网络由输入端(input)、主干网络(backbone)、颈部网络(neck)和输出端(output)4个部分构成。

在输入端采用马赛克数据增强方式,对4张含

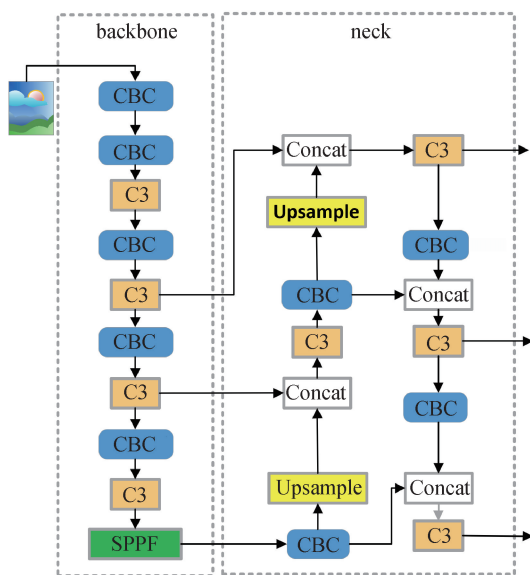


图1 YOLOv5网络结构

Figure 1 YOLOv5 network structure

有目标的图片进行拼接,获得一张图片,增强了网络的鲁棒性,同时加快了图片的读取速度。

输入图像经过主干网络进行特征提取,并得到3种尺度特征的输出。主干网络由CBS模块(convolution batchnorm2d sigmoid linear unit)、C3模块(cross convolutional connection)以及空间金字塔池化模块(spatial pyramid pooling-fast, SPPF)组成。

CBS模块封装了卷积、批归一化和激活函数的组合操作;C3模块是CSP(cross stage partial)结构,主要由瓶颈层模块和3个CBS模块构成,其中瓶颈层模块利用了残差结构来防止梯度爆炸和梯度消失;SPPF模块先将输入图像经过CBS模块,再串行通过卷积核为5的3个最大值池化层,将每次的输出进行拼接,再经过一层CBS提取特征,这样可以加快速度,提高模型的感受野和特征表达能力。

特征融合部分采用特征金字塔网络(feature pyramid networks, FPN)和路径聚合网络(path aggregation network, PAN)相结合的方式。FPN网络自顶向下与主干网络提取的特征进行融合,以提取深层次的语义信息;PAN网络通过采用自底向上传递目标位置信息以减少底层特征信息的丢失,有利于模型更好地学习目标特征,增强模型对小目标的敏感度。

最后将特征融合网络输出的3种不同尺度特征输入到预测部分(predict)进行目标分类与边界框回归,采用非极大值抑制方法保留最优目标框。

YOLOv5的损失主要由3个部分组成:分类损失(classes loss)、置信度损失(object loss)和定位损失(location loss)。其中,分类损失(classes loss)采

用二值交叉熵损失 (binary cross-entropy, BCE loss); 置信度损失 (object loss) 采用网络预测的目标边界框与人工标注框 (ground truth box, GT Box) 的完整交并比 (complete-intersection over union, CIoU) 损失, 计算所有样本的置信度损失; 定位损失 (location loss) 采用 CIoU 损失。

$$Loss = \lambda_1 L_{cls} + \lambda_2 L_{obj} + \lambda_3 L_{loc} \quad (1)$$

式中: $\lambda_1, \lambda_2, \lambda_3$ 为加权参数; L_{cls} 为分类损失, L_{obj} 为置信度损失; L_{loc} 为定位损失。

针对跳频信号检测任务中实时性和计算资源受限的需求, 选用 YOLOv5 框架中的轻量化版本——YOLOv5s, 该架构在保证检测精度的同时显著降低了计算复杂度, 更适合资源受限的实时信号检测场景。

1.2 现存问题

目前, 跳频信号检测识别研究多在高信干比条件下进行, 跳频信号在时频图上较为清晰, 检测结果准确率较高。然而, 在复杂电磁频谱环境下, 通常难以保证高信干比, 强干扰信号将显著降低检测和识别性能, 导致误检和漏检问题。本文首先梳理出干扰对跳频信号检测和识别造成的挑战。

单音和线性调频等干扰信号, 与采用 8PSK 调制的跳频信号在时频图上具有非常相似的特征, 目标检测网络难以区分, 容易造成错检。在时频域, 与跳频信号存在重叠的干扰信号, 会覆盖跳频信号特征, 造成信号漏检。对于一些信号分布较为密集的情况, YOLOv5 网络会将背景与信号置于同一个检测框中, 混乱的检测框会造成多检。当目标检测网络学习了多种调制类型信号特征后, 有些调制信号的时频特征高度相似, 因此, 仅依靠信号的时频特征容易造成调制类型的误检。各种检测错误情况见图 2。

2 改进的 YOLOv5s 网络

2.1 YOLO-Fc 网络

本文提出通过 Focal 网络^[12]改造 YOLOv5s 结




图 2 检测错误情况示意图

Figure 2 Diagram of different detection error cases

构, 引入分层语境化和门控聚合机制扩大网络视野, 增强信号与背景特征的融合能力, 从而提升检测效果与识别率。

Focal 网络使用了聚焦调制 (focal modulation) 替代自注意力模块, 先聚合目标信号周围的上下文信息, 再与信号特征交互得到调制特征。其数学模型如式 (2) 所示:

$$y_i = \Gamma(M(i, X), x_i) \quad (2)$$

式中: i 表示时频图中的位置; X 为整个分析频带内的时频图; $M(i, X)$ 操作表示位置 i 周围的时频聚合特征; $\Gamma(M(i, X), x_i)$ 表示时频图中位置 i 上的信号特征 x_i 与聚合特征 $M(i, X)$ 的交互操作, 以获得信号与背景的融合特征, 其中, $M(i, X)$ 采用语境分层和门控聚合, 扩大 YOLOv5s 网络的感受野, 从时频图获取信号的上下文信息。此外, Γ 是一个轻量级操作符, 采用一个查询映射函数和哈达玛积实现, 其计算复杂度较低。下面, 将改进后的网络称为 YOLO-Fc 网络, 其网络结构如图 3 所示。

由图 3 可以看出, YOLO-Fc 网络主要是改进了 YOLOv5s 网络的 backbone 部分。不同于之前的卷积模块与 C3 模块交替叠加, 本文首先将时频图输

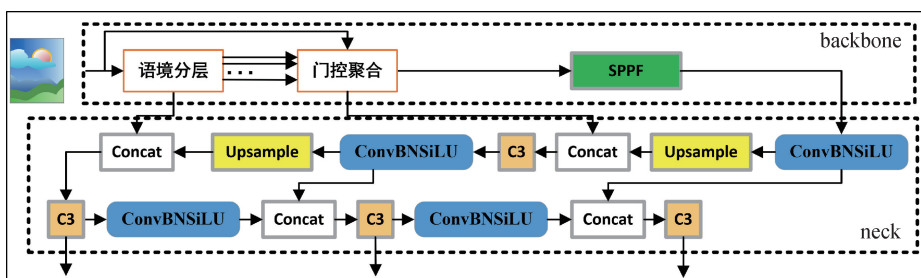


图 3 YOLO-Fc 网络模型

Figure 3 YOLO-Fc network model

入到线性层中,采用深度可分离卷积提取分级的上下文信息;其次,引入门控聚合机制;最后,采用特征加权融合得到融合特征并传递到 SPPF 层。

2.2 语境分层

语境分层模块结构如图 4 所示。




图 4 语境分层模块结构

Figure 4 Contextual layering module structure

为扩大感受野,捕获全局信息,首先,输入时频图特征映射 X ,遍历每个聚焦层级,卷积核的感受野随层级增加而变大,每一层都经过深度可分离卷积和 GeLU 激活函数处理,得到 $(L+1)$ 个分级的特征;其次,对所有特征进行投影,便于后续门控聚合的处理,这个过程的输出表示为

$$Z^\ell = f_a^\ell(Z^{\ell-1}) \triangleq \text{GeLU}(\text{Conv}_{\text{dw}}(Z^{\ell-1})). \quad (3)$$

式中: Z^ℓ 表示第 ℓ 级的特征映射; f_a^ℓ 为第 ℓ 级的分层化函数; Conv_{dw} 为深度可分离卷积; GeLU 为激活函数。最后,对第 L 级特征映射 Z^L 应用平均池化,得到 Z^{L+1} 特征映射,通过语境分层模块,一共得到 $(L+1)$ 个特征映射。

以上过程称为语境分层。通过提取上下文信息,利用语境分层生成的特征图放大感受野,以更粗的粒度捕获更多的上下文信息,可以使网络更容易捕获跳变信号的时频特征,以区分信号与干扰,降低错检与漏检的概率。

2.3 门控聚合

门控聚合模块结构如图 5 所示。在这个模块中,将 X 通过线性层进行分离,分别可以得到信号特征 x_i ,上下文特征 ctx ,门控权重 G 。在时频图像中,会根据检测目标不同设定不同的级别。遍历每个层级,将语境分层模块得到的 $(L+1)$ 个特征映射与该层门控权重 G 相乘,最后整体相加得到聚合特征 Z^{out} ,即

$$Z^{\text{out}} = \sum_{\ell=1}^{L+1} G^\ell \odot Z^\ell. \quad (4)$$

式中: $G = f_g(X) \in \mathbf{R}^{H \times W \times (L+1)}$; \odot 为哈达玛积。最后将调制特征输入到 SPPF 层。

门控聚合模块通过加入分层的特征融合机制,

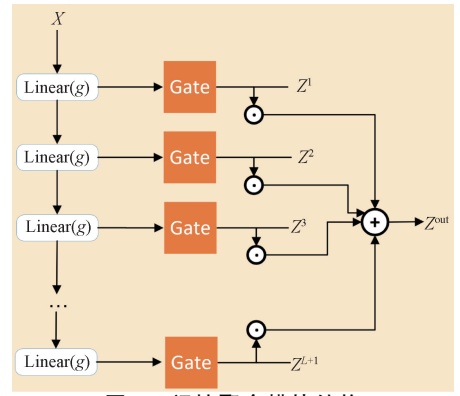


图 5 门控聚合模块结构

Figure 5 Gated aggregation module structure

同时学习粗粒度的空间信息,即背景信息和细粒度的信号特征信息,从而大幅度提高网络的信号检测与识别性能。

2.4 总结

YOLO-Fc 网络通过语境分层结构融合多尺度上下文信息,使低层特征同时具备大感受野和高细节保留能力,并结合门控聚合机制自适应融合粗细粒度特征,从而显著提升检测与定位精度。相较于 YOLOv5, YOLO-Fc 在强干扰环境下可实现跳频信号检测与识别率的显著提升。

3 实验设计

3.1 实验环境

实验环境: CPU 型号为 Intel Core i7-12700H, 内存为 16 GB, 显卡类型为 RTX 3060, 显存为 8 GB, Python 版本为 3.8。

3.2 数据集生成

本文数据集构建的跳频信号参数设置为: 跳频速率 ≥ 8000 跳/秒, 带宽 98 MHz, 包含 51 个频点, 调制方式覆盖 8PSK、16QAM、32QAM 和 64QAM 等典型高阶调制。通过覆盖低阶至高阶调制, 能全面评估系统在多种信号条件下的识别性能, 同时考察模型对频谱利用率、抗干扰能力和实现复杂度的适应性和鲁棒性。

为分析 YOLO-Fc 网络的性能, 本文设计了多种干扰信号, 包括带宽 30 MHz 的线性调频干扰 (linear frequency modulation, LFM)、调幅系数为 3 且带宽为 15 MHz 的噪声调幅干扰 (noise-AM jamming, NAM)、调频系数为 0.2 且带宽 20 MHz 的噪声调频干扰 (noise-FM jamming, NFM)、带宽为 30 MHz 的射频噪声干扰 (noise modulated jamming, NMJ)、脉冲间断噪声干扰 (pulse interval noise jamming, PINJ), 以及单音干扰 (single-tone jamming, STJ), 所有干扰的中心频率均在跳频信号带宽内。

数据集生成基于 MATLAB 仿真平台,在信干比为 5 dB、信噪比为 10 dB 的条件下分别生成调制信号、干扰信号及噪声。选择该信干比和信噪比旨在创建具有一定挑战性但可控的环境,以便测试算法在现实条件下的鲁棒性。将调制信号、干扰信号和噪声叠加后采用短时傅里叶变换生成时频图,每种调制与干扰组合生成 300 个样本,总计 7 200 个样本,按 90:5:5 比例划分为训练集、验证集和测试集。

3.3 训练步骤

步骤 1 对所有图片进行标签操作,利用 LabelImg 工具对所有图片进行标签操作,保存生成的 xml 文件,LabelImg 标签界面如图 6 所示。




图 6 LabelImg 标签界面

Figure 6 LabelImg tagging interface

步骤 2 将 xml 文件转换为适用于 YOLOv5s 网络的 txt 文件,按比例随机生成训练集、测试集和验证集。

步骤 3 YOLO-Fc 网络的初始学习率设置为 0.010 0,多轮训练后学习率减小至 0.000 1,训练批次大小设置为 16,进行 300 轮训练。

4 实验结果与分析

4.1 评价指标

为确保实验可比性,本文使用相同的实验设置进行训练与测试,并采用精确率 P 、召回率 R 来评估实验效果,具体计算过程如下:

$$P = \frac{TP}{TP + FP} \times 100\%; \quad (5)$$

$$R = \frac{TP}{TP + FN} \times 100\%。 \quad (6)$$

式中: TP 为检测正确的目标数量; FP 为检测错误的目标数量; FN 为漏检的目标数量。

$F1$ 为精确率和召回率的加权平均。 $F1$ 的最优值为 1,最差值为 0, $F1$ 的计算公式为

$$F1 = 2 \cdot \frac{P \cdot R}{P + R}。 \quad (7)$$

以召回率和精确率分别为横坐标和纵坐标,绘出 R - P 曲线,对曲线求积分为平均精准度 AP 值。由于考虑了多个类别的识别,其平均值记为平均精度均值 mAP ,用来衡量模型对所有类别的检测效果,计算公式如下:

$$AP = \int_0^1 P dR; \quad (8)$$

$$mAP = \frac{\sum_{i=0}^N AP_i}{N}。 \quad (9)$$

式中: N 为数据集中检测目标的类别数; i 为当前类别的编号。考虑 8PSK、16QAM、32QAM 和 64QAM 4 种调制类型分析网络的检测和识别性能,本文实验设置 $N=4$ 。

4.2 训练结果分析

各指标曲线如图 7 所示。由图 7 可以看出,当训练迭代分别到第 82 轮和第 56 轮后, P 和 R 趋于平稳,当训练迭代到第 52 轮后, mAP 也趋于稳定,证明了改进模型的稳定性。

图 8 为得到的混淆矩阵,由图 8 可以看出各个种类的调制信号都能够被准确区分。

4.3 指标对比分析

本文在此实验中分别训练了改进的 YOLOv5s 网络和原始的 YOLOv5s 网络,同时,本文还进行了其他 YOLO 系列网络^[13-14]的训练,表 1 为各指标性能对比。




图 7 指标曲线

Figure 7 Index curve

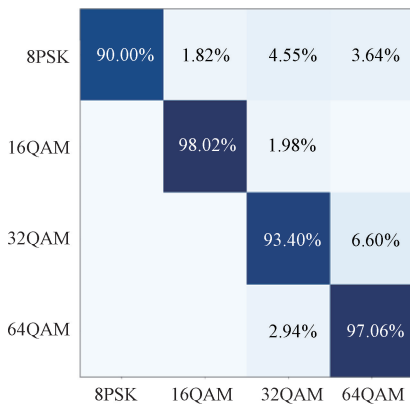


图8 混淆矩阵

Figure 8 Confusion matrix

表1 不同模型性能对比

Table 1 Performance comparison of different models %

模型	P	R	$mAP@0.5$	$mAP@0.5:0.95$
YOLOv5s	99.1	83.2	93.8	71.2
YOLOv7s	99.2	88.1	94.4	72.3
YOLOv8s	99.5	90.2	95.6	75.0
YOLO-Fc	99.6	99.1	99.3	80.1

引入 YOLO-Fc 网络后,相较于其他 YOLO 系列网络,精确率略有提升,召回率提升显著,相比 YOLOv5s 提升 15.9 个百分点, $mAP@0.5$ 提升 5.5 个百分点, $mAP@0.5:0.95$ 提升 8.9 个百分点,体现了模型的有效性和鲁棒性。YOLO 系列网络为提高精度往往会牺牲召回率,导致漏检率较高;而 YOLO-Fc 则在精确率和召回率上达到平衡,不为精确率牺牲召回率,也不为召回率牺牲精确率。图 9 为 YOLOv5s 和 YOLO-Fc 的 $F1$ 曲线对比。由图 9 可知,综合全部 4 种调制方式的数据计算结果(all)可知,YOLO-Fc 相比 YOLOv5s, $F1$ 提升 9 个百分点。

具体到每种调制类型信号,各参数结果如表 2 所示。由表 2 可以看出,对于不同的调制类型,YOLO-Fc 网络与 YOLOv5s、YOLOv7s 和 YOLOv8s 相比,在 P 、 R 、 mAP 3 种性能指标上大部分数值有所提升。

4.4 模型检测对比分析

在相同的硬件条件下,利用训练得到的模型对时频图进行测试,模型检测结果对比如图 10、11 所示。通过对比可以看出,YOLO5-Fc 置信度有了明显的提升,在干扰附近的提升较大。除此之外,频率变化较小,导致频谱图比较密集,并且处于干扰之中的情况,原始 YOLOv5s 网络会出现多检、漏检,如图

10(a) 所示;对于信号特征不明的情况则会出现错检,如图 11(a) 所示。而 YOLO-Fc 几乎不存在多检、漏检及错检等现象。

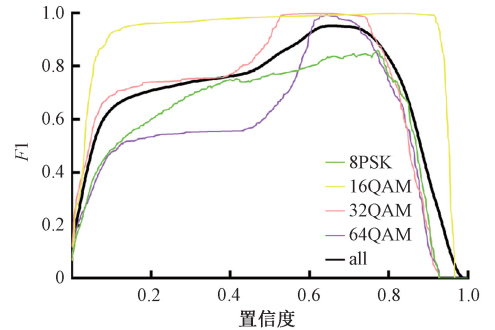
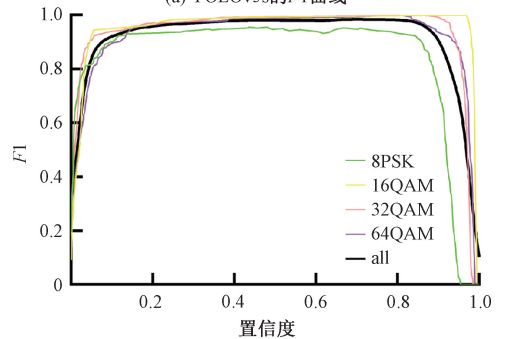
(a) YOLOv5s的 $F1$ 曲线(b) YOLO-Fc的 $F1$ 曲线图9 $F1$ 曲线对比Figure 9 $F1$ Curve comparison

表2 不同网络模型在各调制类型信号的指标对比

Table 2 Comparison of indicators of different network models in signals of each modulation type %

模型	调制类型	P	R	$mAP@0.5$	$mAP@0.5:0.95$
YOLOv5s	8PSK	97.5	96.1	98.6	60.7
	16QAM	99.7	100	99.5	85.4
	32QAM	99.8	72.8	94.2	76.6
	64QAM	99.1	64.0	82.7	62.2
YOLOv7s	8PSK	97.8	96.3	98.8	61.2
	16QAM	99.6	100.0	99.5	85.8
	32QAM	99.8	79.8	94.5	78.0
	64QAM	99.5	72.2	85.5	65.2
YOLOv8s	8PSK	98.2	96.5	98.9	64.8
	16QAM	99.9	100.0	99.5	86.0
	32QAM	99.8	89.3	96.6	81.9
	64QAM	99.7	85.2	90.9	78.3
YOLO-Fc	8PSK	98.7	96.3	98.6	66.2
	16QAM	99.9	100.0	99.5	86.8
	32QAM	99.8	100.0	99.5	83.3
	64QAM	99.8	100.0	99.5	84.3

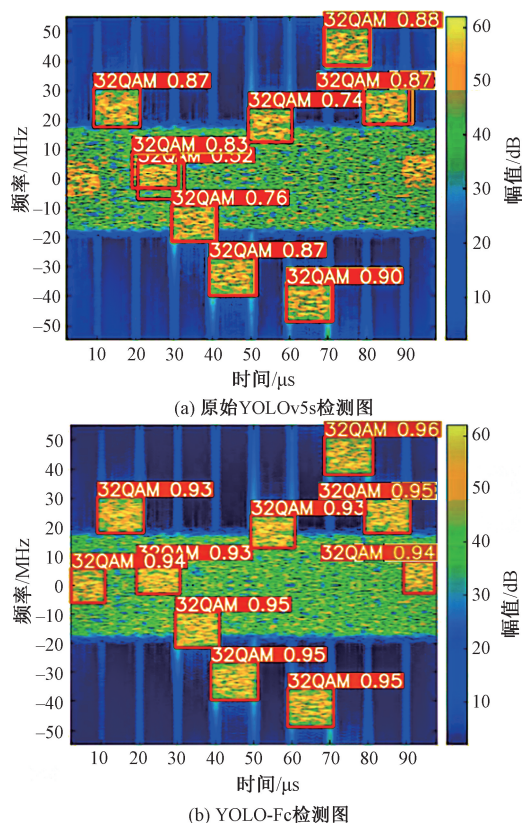


图 10 模型检测结果对比 1

Figure 10 Comparison of model detection results 1

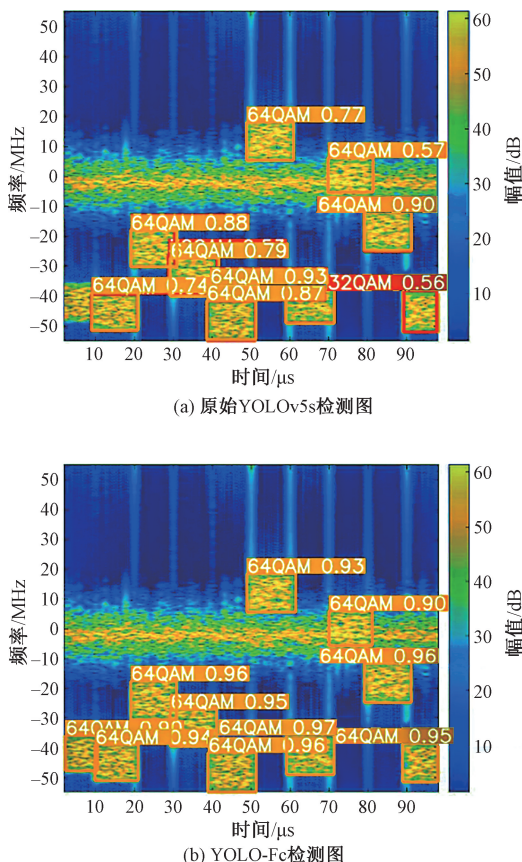


图 11 模型检测结果对比 2

Figure 11 Comparison of model detection results 2

5 结论

本文通过在 YOLOv5s 网络中引入语境分层和门控聚合机制扩展了网络的感受野,并使其能够更有效地学习和理解目标信号的上下文信息。这种改进不仅增强了网络对信号时间和频率特征的感知能力,也显著提高了在复杂信号环境中的检测和定位精度。

实验结果表明, YOLO-Fc 网络在减少错检和漏检方面提升明显,其 P 和 R 指标的提升反映了网络在维持检测准确性的同时,也显著提高了对目标信号的识别率,证明 YOLO-Fc 网络在 P 和 R 之间达到了更好的平衡,使得模型能够更加准确地识别和定位在电磁干扰条件下的信号。

参考文献:

[1] 李红光, 郭英, 睦萍, 等. 基于时频能量谱纹理特征的跳频调制方式识别[J]. 通信学报, 2019, 40(10): 20-29.
 LI H G, GUO Y, SUI P, et al. Frequency hopping modulation recognition based on time-frequency energy spectrum texture feature [J]. Journal on Communications, 2019, 40(10): 20-29.

[2] 张萌, 王文, 任俊星, 等. 基于 HOG-SVM 的跳频信号检测识别算法[J]. 信息安全学报, 2020, 5(3): 62-77.
 ZHANG M, WANG W, REN J X, et al. Detection and recognition algorithm for frequency hopping signals based on HOG-SVM [J]. Journal of Cyber Security, 2020, 5(3): 62-77.

[3] 胡晓芳. 基于稀疏性的跳频信号检测技术研究[D]. 哈尔滨: 哈尔滨工程大学, 2018.
 HU X F. Research on frequency hopping signal detection technology based on sparsity [D]. Harbin: Harbin Engineering University, 2018.

[4] HUANG D K, YAN X P, HAO X H, et al. Low SNR multi-emitter signal sorting and recognition method based on low-order cyclic statistics CWD time-frequency images and the YOLOv5 deep learning model [J]. Sensors, 2022, 22(20): 7783.

[5] 周凯. 基于 YOLOv5 的跳频信号调制方式检测识别[J]. 数字通信世界, 2022(11): 8-10.
 ZHOU K. Detection and identification of frequency hopping signal modulation based on YOLOv5 [J]. Digital Communication World, 2022(11): 8-10.

[6] WANG Y Y, HE S R, WANG C R, et al. Detection and parameter estimation of frequency hopping signal based on the deep neural network [J]. International Journal of E-

- lectronics, 2022, 109(3): 520–536.
- [7] CHOLLET F. Xception: deep learning with depthwise separable convolutions [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2017: 1800–1807.
- [8] GIRSHICK R. Fast R-CNN [C]//2015 IEEE International Conference on Computer Vision. Piscataway: IEEE, 2015: 1440–1448.
- [9] 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.
- [10] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2016: 779–788.
- [11] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector [C]//Lecture Notes in Computer Science. Cham: Springer, 2016: 21–37.
- [12] YANG J W, LI C Y, DAI X Y, et al. Focal modulation networks [EB/OL]. (2022-03-22) [2025-01-02]. <https://doi.org/10.48550/arXiv.2203.11926>.
- [13] WANG C Y, BOCHKOVSKIY A, LIAO H Y 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. Piscataway: IEEE, 2023: 7464–7475.
- [14] VARGHESE R, SAMBATH M. YOLOv8: A novel object detection algorithm with enhanced performance and robustness [C]//2024 International Conference on Advances in Data Engineering and Intelligent Computing Systems. Piscataway: IEEE, 2024: 1–6.

Modulation Recognition of Frequency Hopping Signal under Interference Based on Improved YOLOv5s

ZHANG Haibin¹, WEI Hongji¹, WANG Chao², XIANG Changbo³, YANG Mingyang³, LI Xiaolong⁴

(1. Hangzhou Research Institute, Xidian University, Hangzhou 311200, China; 2. School of Telecommunications Engineering, Xidian University, Xi'an 710126, China; 3. Ceyear Technologies Co., Ltd., Qingdao 266555, China; 4. Beijing Institute of Control and Electronic Technology, Beijing 100038, China)

Abstract: In complex electromagnetic environments, interference signals can severely degrade the detection and recognition performance of frequency-hopping signals. To address issues of false detection, missed detection, and over-detection in traditional methods, in this study an improved time-frequency diagram-based signal detection and recognition algorithm was proposed by modifying the YOLOv5s network. Firstly, a composite dataset containing frequency hopping signals + interference signals was constructed, comprising 4 modulation types of frequency hopping signals and 6 interference types, with 300 high-resolution time-frequency diagram samples generated for each combination (totaling 7 200 groups). Secondly, considering the similar features between interference and signals in time-frequency diagrams, and recognizing that the frequency variation pattern of hopping signals could make background information around signals crucial for differentiation, a context hierarchy module was proposed to hierarchically process background information. This module employed depthwise separable convolution to extract surrounding background features and utilized a gated aggregation mechanism to perform weighted fusion of background information and signal features, thereby generating more discriminative composite features. Finally, the backbone network of YOLOv5s was modified by integrating the context hierarchy module and gated aggregation mechanism to develop an improved frequency hopping signal detector. Simulation results showed that compared with the original YOLOv5s network, the proposed method achieved 15.9 percentage points improvement in recall rate R , 8.9 percentage points enhancement in mean average precision $mAP@0.5:0.95$, and 9 percentage points increase in $F1$, while significantly reducing false and missed detection occurrences.

Keywords: frequency hopping signal; signal detection; signal recognition; interference signal; YOLOv5s