

# 基于改进 YOLOv8n 的通信终端识别算法

张 策<sup>1</sup>, 苏思雨<sup>2</sup>

(1. 佳缘科技股份有限公司, 四川 成都 610097; 2. 杭州电子科技大学 通信工程学院, 浙江 杭州 310018)

**摘要:** 针对复杂电磁环境下信号干扰引起的通信设备终端识别精度下降这一问题, 提出一种基于改进 YOLOv8n 的通信设备终端识别算法 EMI-YOLO。首先, 针对干扰信号对目标信号造成遮挡干扰问题, 通过将深度卷积、逐点卷积和 ECA (Efficient Channel Attention) 注意力机制相融合, 提出 C2fCE 模块以增加模型感受野; 其次, 在主干网络的末端嵌入部分自注意力机制, 提高模型对信号特征的学习能力; 再次, 采用五种数据增强策略对数据集进行有效扩充。实验结果表明, 在训练集上, EMI-YOLO 模型相比 YOLOv8n 模型 mAP50-95 提升 7.4%, 模型参数量减小 0.4M; 在测试集上, 相比 3 个对比算法, EMI-YOLO 模型对六个手机型号的识别准确率分别平均提高 42.3%、52%、53.4%、50.4%、34% 和 39.7%。因此, EMI-YOLO 模型在复杂电磁环境下具有较强的抗干扰能力和鲁棒性。

**关键词:** 通信终端识别; YOLOv8n; 复杂电磁环境

**中图分类号:** TP393      **文献标志码:** A      **DOI:** 10.19358/j.issn.2097-1788.2026.01.004

**中文引用格式:** 张策, 苏思雨. 基于改进 YOLOv8n 的通信终端识别算法 [J]. 网络安全与数据治理, 2026, 45(1): 20-28.

**英文引用格式:** Zhang Ce, Su Siyu. Emitter identification algorithm for communication terminals based on improved YOLOv8n [J]. Cyber Security and Data Governance, 2026, 45(1): 20-28.

## Emitter identification algorithm for communication terminals based on improved YOLOv8n

Zhang Ce<sup>1</sup>, Su Siyu<sup>2</sup>

(1. Jiayuan Science and Technology Co., Ltd., Chengdu 610097, China;

2. School of Communication Engineering, Hangzhou Dianzi University, Hangzhou 310018, China)

**Abstract:** To address the issue of decreased identification accuracy of communication terminals caused by signal interference in complex electromagnetic environments, an improved YOLOv8n-based emitter identification algorithm for communication terminals is proposed, named EMI-YOLO. Firstly, to tackle the problem of interference signals occluding the target signal, a C2fCE module is proposed, which integrates deep convolution, pointwise convolution, and the Efficient Channel Attention (ECA) mechanism to expand the model's receptive field. Secondly, a partial self-attention mechanism is embedded at the end of the backbone network to enhance the model's ability to learn signal features. Furthermore, five data augmentation strategies are employed to effectively expand the dataset. The experimental results indicate that EMI-YOLO demonstrates a 7.4% improvement in mAP50-95 than YOLOv8n in the training set, with a reduction of 0.4M in model parameters; compared to three baseline algorithms, EMI-YOLO improves the identification accuracy for six mobile phone models by an average of 42.3%, 52%, 53.4%, 50.4%, 34% and 39.7% in the test set, respectively. Therefore, EMI-YOLO exhibits strong anti-interference capability and robustness in complex electromagnetic environments.

**Key words:** communication terminal identification; YOLOv8n; complex electromagnetic environment

## 0 引言

近年来, 随着无线电网络的迅猛发展, 智能手机、物联网设备以及各种无线传感器等设备的大量涌人, 使得无线网络变得更加复杂和密集, 信息安全问题也

日益突出<sup>[1]</sup>。例如, 现有的无线网络大多依赖于密钥进行身份验证, 但密钥一旦泄露, 就容易发生非法用户的接入或者数据被窃取等事件<sup>[2]</sup>, 导致严重的信息安全问题。

通信终端辐射源识别为此类信息安全问题提供另外一种防御途径。除验证密钥外，还验证无线设备的型号与预留的型号是否一致，以此增强数据访问的安全性。具体来说，通过深度学习技术提取射频指纹（RFF）特征来发现和识别异常行为<sup>[3]</sup>，从而及时阻止非法设备的接入，进而确保通信的安全性和可靠性，提升无线网络的防护能力。

然而，生活中充斥着电子设备、通信系统、电台、无线网络等大量辐射源，各种信息设备所产生的强电磁波、密集电磁场以及自然界中各种电磁信号，构成日益复杂的电磁环境<sup>[4]</sup>。电磁信号强度的动态变化、密集交织的信号以及频谱的重叠与紧密分布可能会对目标信号产生遮挡<sup>[5]</sup>，现有的基于深度学习的特征提取技术面对复杂多变的电磁环境时，模型容易受到干扰信号的影响，导致对目标信号的辨识能力下降。因此，复杂的电磁环境给通信终端的辐射源识别带来巨大挑战。

近年来，基于 YOLO 的目标识别算法在多个领域得到广泛应用，并衍生出大量改进方法。第一种思路是通过降低模型计算量来增强算法的实时性。例如，RF-YOLO 针对无人机通信信号识别在 YOLOv8 基础上改进主干与 Neck 结构，实现了参数量与精度的平衡<sup>[6]</sup>。这类方法在边缘设备部署和实时检测任务中具有明显优势，但在复杂场景下可能会降低特征表达能力。第二种思路是提升模型对关键特征的提取能力。例如，YOLOv5s-CWMDSQ 在主干中引入 CA 注意力和多尺度池化机制，有效提升了频谱信号识别的精度<sup>[7]</sup>。这类方法能够强化对目标信息的关注，从而提高识别精度，但大多直接将注意力模块堆叠在主干网络上，模型的泛化能力仍有限。第三种思路是进行特征融合。如在 YOLO 的 Neck 部分引入 PANet<sup>[8]</sup> 等结构实现多尺度特征融合。然而在频谱类图像中，多尺度信息的有效利用仍面临挑战。

针对通信终端设备识别问题，本文创新性地提出基于数字频谱余晖图和改进 YOLO 的通信终端识别算法。具体来说，采用 YOLO 目标识别框架，提取通信终端辐射源的数字频谱余晖图特有的 RFF 特征，提出适用于复杂电磁环境的通信终端识别算法，简称 EMI-YOLO。其核心包括三点：针对干扰信号对目标信号造成遮挡干扰问题，提出 C2FCE 模块，嵌入到主干和颈部网络；针对模型特性提取能力弱问题，在主干网络的末端嵌入部分自注意力机制；针对数据集样本较少问题，采用五种数据增强策略对数据集进行有效扩充。实验结果表明，相较于基准算法，在模型

参数量减少的条件下，EMI-YOLO 的识别准确率得到提高。

## 1 相关基础

### 1.1 数字频谱余晖图

数字频谱余晖图<sup>[9]</sup>是一种关键、可靠的信号分析工具，可呈现信号的波动形势、所处方位、强度以及频率等信息，为复杂电磁环境里信号的监测与分析提供可视化图像。数字频谱余晖图的基础是数字荧光技术（DPX），它可以在短时间内通过高速的离散傅里叶变换（DFT）将信号进行时域频域的转换，在位图数据库中累积大量的频谱图，生成动态的、可视化的数字频谱余晖图<sup>[9]</sup>。具体来说，DPX 能将一段时间内所有信号的频谱信息累积，并以图像形式展示出来。

图 1 为数字频谱余晖图构建实例，显示频谱映射到位图数据库后的存储内容。图 1 前 3 个图单元格中的数值表示频谱命中的次数<sup>[10]</sup>，如果单元格中没有数值，就意味着这个幅度的频谱未出现过。图 1 (a) 表示一帧频谱转换到数据库后显示的内容。图 1 (b) 展示经过 9 次频谱变换后数据库中累积的结果，单元格中的值表示命中该格的统计次数。图 1 (c) 是基于 9 个频谱统计次数绘制的数据库单元格颜色的结果，通过将累积的计数值与颜色标度相关联，就可以将数据转换为亮度信息，从而生成彩色图。图 1 (d) 是最终通过 DPX 技术得到的数字频谱余晖图。

### 1.2 数据集构建

由于基于数字频谱余晖图的通信终端识别无开源公开数据集，针对此问题，本文在无干扰环境、弱干扰环境和强干扰环境三种不同程度的电磁环境中搭建图 2 所示的信号采集系统。具体来说，实验所用无干扰环境为夜晚地下车库的密闭房间，弱干扰环境为夜晚的办公大楼房间，强干扰环境为白天正常工作时间的办公大楼房间，以各种通信设备、无线网络、打印机、智能手环等为干扰源，构建适用于复杂电磁环境中通信设备终端识别（CDTR）数据集。

信号采集系统由一部 OmniLoG70600 全向宽频天线、一台 SRP-600B 信号记录回放仪、一台装有 SignalMg-PC 软件的计算机和一台波形显示器组成。采集流程如下：首先，由六个型号的手机分别发出 Wi-Fi 热点信号；其次，全向宽频天线将捕获的信号传送给信号记录回放仪进行初步处理；然后，通过计算机设备调整接收信号带宽、中心频率等参数；最后，信号波形通过 SignalMg-PC 软件以数字频谱余晖图的形式在显示屏上呈现、记录和保存，便于后续的数据分析与处理。

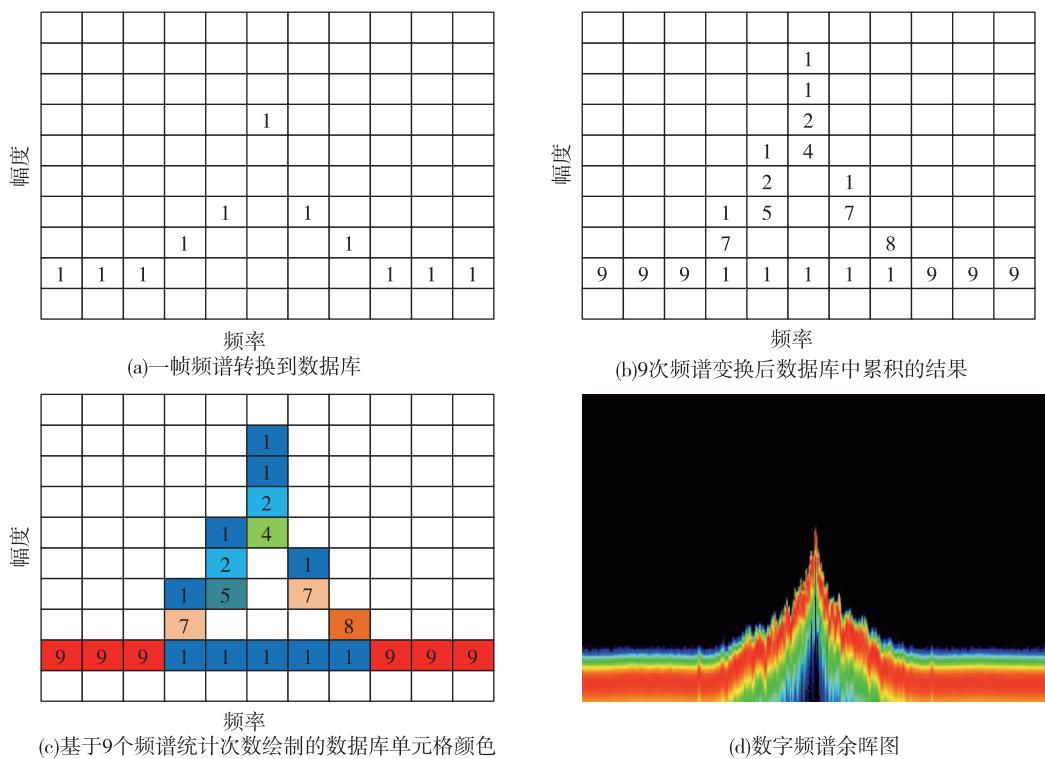


图 1 数字频谱余晖图构建实例

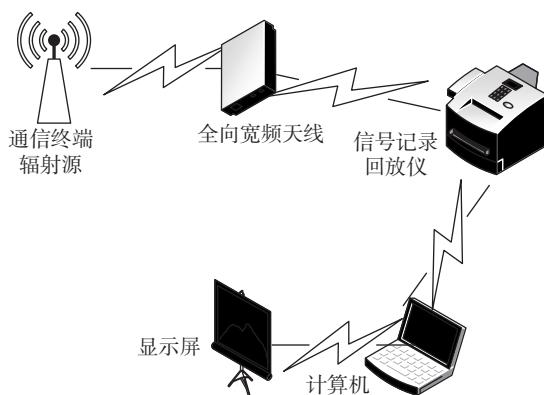


图2 信号采集系统

本文以 nova 9、nova 7 Pro、nova 7 se、Redmi K40、iPhone 11、vivo iQOO 六种通信设备为实验对象，采集在 2.4 GHz 频段下发出的热点信号。然后对无干扰环境中采集到的信号进行数据标注，使用标注软件 LabelImg 进行类别的划分和标注框的选定，生成可扩展标记语言文件。CDTR 数据集是以无干扰环境下采集到的信号作为训练样本和验证样本，同时以干扰环境（弱干扰环境和强干扰环境）下采集到的信号作为测试样本，共计 3 300 张，具体分布如表 1 所示。这些设备在干扰或无干扰环境下热点信号的数字频谱余晖图如图 3、图 4 所示。

表 1 数据集分布

类别	训练集	验证集	测试集
nova 9	400	50	100
nova 7 Pro	400	50	100
nova 7 se	400	50	100
Redmi K40	400	50	100
iPhone 11	400	50	100
vivo iQOO	400	50	100
总计	2 400	300	600

### 1.3 评价指标

为对模型性能进行准确评估,本文采用精确率( $P$ )、召回率( $R$ )、平均精度(AP)、均值平均精度(mAP)、模型参数量和每秒10亿次的浮点运算数(GFLOPs)作为评价指标。mAP又分为mAP50和mAP50-95,其中mAP50代表交并比(IOU)阈值取0.5时的平均精度,mAP50-95表示IOU阈值从0.5开始以0.05为步长逐渐增加到0.95时不同阈值下的平均mAP值。这些指标的计算公式如下:

$$P = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (1)$$

$$R = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (2)$$

其中 TP 表示将正样本正确识别的数量, FN 表示将正

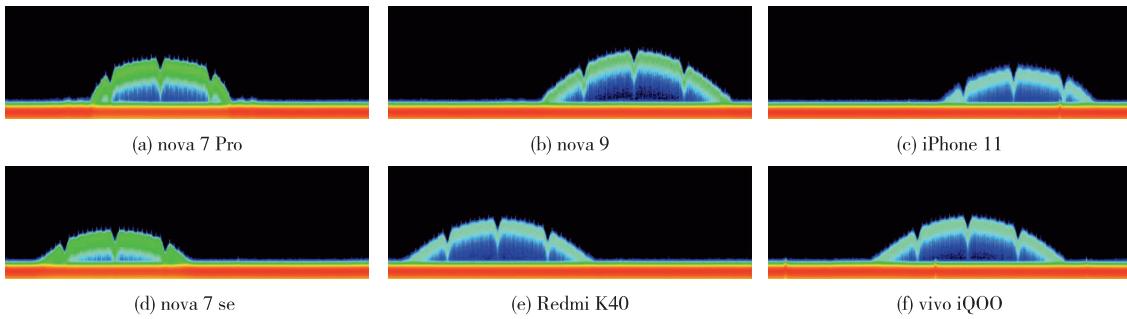


图3 无干扰环境下的数字频谱余晖图

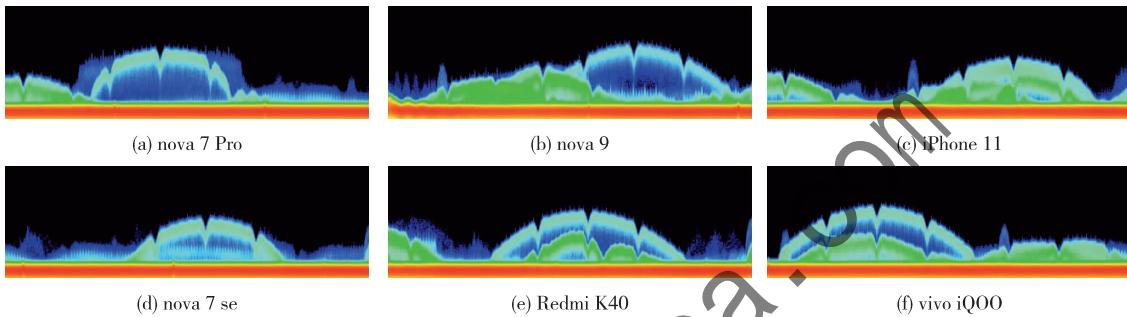


图4 干扰环境下的数字频谱余晖图

样本错误预测为负样本的数量, FP 表示将负样本错误预测为正样本的数量。

$$\text{AP} = \int_0^1 P(R) \, dR \quad (3)$$

$$\text{mAP} = \frac{1}{C} \sum_{i=1}^c \text{AP}_i \quad (4)$$

其中  $C$  表示类别数,  $\text{AP}_i$  表示第  $i$  个类别的 AP 值。

## 2 EMI-YOLO 识别算法

### 2.1 EMI-YOLO 整体架构

EMI-YOLO 网络结构如图 5 所示, 由主干网络

(Backbone)、颈部网络 (Neck) 与检测头 (Head) 三部分组成。首先信号的数字频谱余晖图作为输入进入主干网络部分, 依次通过 CBS 模块和 C2fCE 模块, 改变特征图的尺寸和通道数, 其中, C2fCE 模块通过使用两个不同大小的卷积核来代替传统的  $3 \times 3$  卷积核, 降低模型参数量的同时减少计算量。SPPF (Spatial Pyramid Pooling Fast) 模块通过不同尺寸的池化窗口捕捉多尺度的特征, 增强模型对不同尺寸目标的检测能力。

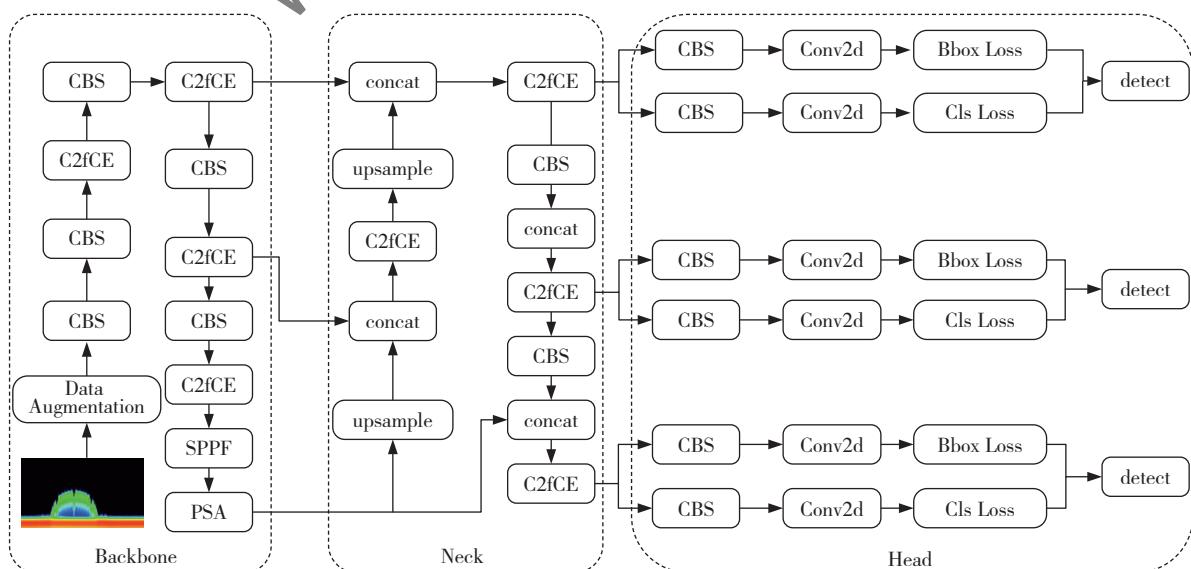


图5 EMI-YOLO 网络结构

另外,本文在 Backbone 的最后添加部分自注意力机制 (PSA), 增强网络的学习能力。紧接着, 三个不同尺寸的特征图进入颈部网络, Neck 层使用上采样操作, 将高分辨率的特征图与主干网络中的特征图进行拼接, 保留高层语义信息。Head 层采用解耦头结构, 将分类和检测任务分离开, 分类损失采用的是 BCE Loss, 回归损失采用了 DFL (Distribution Focal Loss) 和 CIOU (Complete Intersection Over Union) 损失, 这种设计允许模型的每个部分专注于其特定的任务, 提高模型在复杂场景下的性能。

## 2.2 C2fCE 模块

为解决模型在训练中存在的信息丢失问题, 提高模型对信号的识别精度, 本文优化 C2f 模块, 使用 CE 结构替换 C2f 中的 Bottlenet 结构, 通过融合深度卷积、点卷积和 ECA 注意力机制, 提出 C2fCE 模块, 其结构如图 6 所示, 在保证 YOLOv8n 模型轻量化的同时, 提高识别准确率。

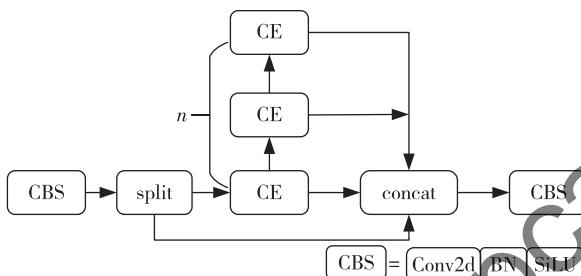


图 6 C2fCE 模块结构

图 6 中, 首先将输入数据经过第一个卷积层, 然后将输出分为两个部分, 分支操作有助于增加网络的非线性和表示能力, 从而提高网络对复杂数据的建模能力。其中一部分直接传递给输出, 另一部分经过多个 CE 模块的处理, CE 模块的数量由模型的深度参数定义, 其结构如图 7 所示。最后, 两个部分的结果在通道维度上进行拼接, 实现特征融合。拼接后的特征将包含来自不同分支的信息, 丰富特征的表达能

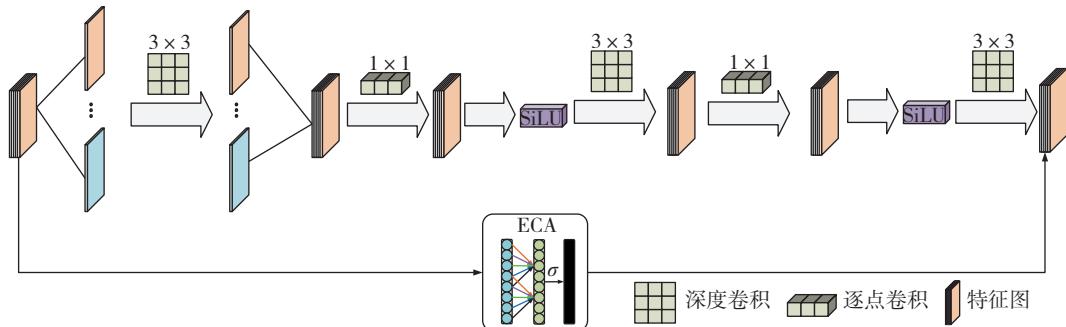


图 7 CE 模块结构

力, 并经过第二个卷积层得到最终的输出。

图 7 中, CE 被划分为两个分支。一个分支通过  $3 \times 3$  的深度卷积块, 将输入图像和卷积核按照通道划分, 在不同通道上分别独立地进行特征提取; 随后将输出张量堆叠, 并通过  $1 \times 1$  的逐点卷积执行跨通道的特征融合, 将上一步得到的特征图进行深度的加权组合产生新的特征图。另一个分支通过 ECA 注意力机制自适应地调整通道特征的权重, 使得网络可以更好地关注重要的特征, 抑制不重要的特征。CE 模块通过深度卷积分通道进行深度特征抽取, 逐点卷积进行多通道特征融合, 降低模型参数量。SiLU 激活函数引入非线性因素, 在缓解梯度消失的同时增加了网络的学习能力。在不增加过多参数和计算成本的情况下, 嵌入 ECA 注意力机制, 在 CE 模块中, 为了实现跨通道信息的自适应交互, ECA 注意力机制根据输入特征图的通道数  $C$  动态确定卷积核大小  $k$ , 具体公式为:

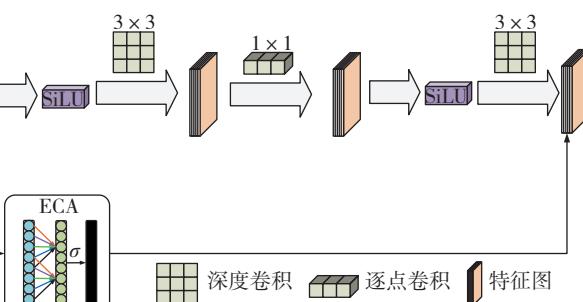
$$k = \psi(C) = \lfloor \frac{\log_2 C}{\gamma} + b \rfloor_{\text{odd}} \quad (5)$$

其中,  $\gamma$  和  $b$  为经验超参数, 本文取  $\gamma = 2$ ,  $b = 1$ ;  $\lfloor \cdot \rfloor_{\text{odd}}$  表示取最近的奇数以保证卷积核为奇数。这样设计使得通道数较大的层使用更大的卷积核, 从而可以捕获更多跨通道信息, 提高特征表达能力, 而不显著增加计算成本。

## 2.3 PSA 机制

由于复杂环境中存在着较多的信号干扰, 原 YOLOv8n 模型无法对通信终端进行准确的识别。本文在 YOLOv8n 的主干网络末端嵌入 PSA 机制, 其结构如图 8 所示, 使网络具有全局建模能力, 增强模型对复杂环境中信号的分辨能力。

图 8 中, 首先将输入特征通过  $1 \times 1$  卷积分为两个分支, 其中一支直接传递, 另一支送入多头自注意力 (MHSAs) 模块与卷积单元以增强全局建模能力。设输入特征为  $X \in \mathbb{R}^{H \times W \times C}$ , 其在 MHSAs 中的计算过程可表示为:



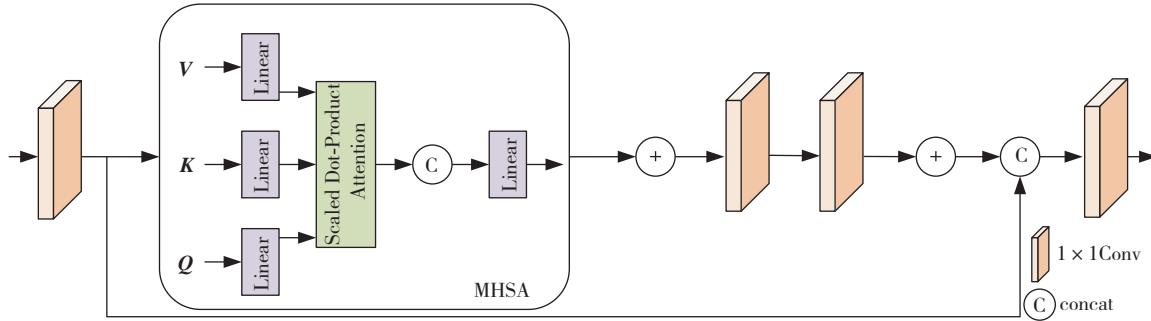


图 8 PSA 模块结构

$$\begin{cases} Q = XW_Q \\ K = XW_K \\ V = XW_V \end{cases} \quad (6)$$

其中  $W_Q$ ,  $W_K$ ,  $W_V$  为可学习的线性变换矩阵。本文设定注意力头数为  $h = 3$ , 则每个注意力头的维度为:

$$d_k = \frac{C}{h} \quad (7)$$

在每个注意力头中, 查询、键和值分别被划分为  $(Q_i, K_i, V_i)$ ,  $i = 1, 2, 3$ , 并通过缩放点积注意力机制计算:

$$\text{Attention } (Q_i, K_i, V_i) = \text{softmax} \left( \frac{Q_i K_i^T}{\sqrt{d_k}} \right) V_i \quad (8)$$

随后, 将所有注意力头的输出在通道维度上拼接, 并经由线性变换得到融合特征。最终, 该特征与另一分支通过  $1 \times 1$  卷积进行整合, 从而实现出全局上下文信息的建模与表达。

## 2.4 数据增强

由于构建的初始数据集样本较少, 本文采用数据增强 (Data Augmentation, DA) 技术对其进行扩充。DA 通过对已有数据添加微小改动或过采样人为地扩大数据集的方法, 可以防止模型过拟合<sup>[11]</sup>。

如图 9 所示, 数据增强策略主要分为几何变换和像素变换。本文将每个样本进行五个子策略操作, 每个子策略由三个图像增强操作按固定顺序组合, 如表 2 所示。图 10 给出经过五个子策略处理后的示例图。

表 2 数据增强子策略及参数设置

子策略	操作顺序	参数说明
1	裁剪→高斯噪声→高斯模糊	裁剪比例 0.8 ~ 1.0; 噪声方差 0.01; 模糊核 $3 \times 3$
2	翻转→cutout→高斯模糊	水平翻转概率 0.5; cutout 遮挡比例 0.1 ~ 0.3; 模糊核 $3 \times 3$
3	旋转→缩放→调节亮度	旋转角度 $\pm 15^\circ$ ; 缩放比例 0.9 ~ 1.1; 亮度调节 $\pm 0.2$
4	旋转→缩入→cutout	同上, cutout 遮挡比例 0.1 ~ 0.3
5	旋转→镜像→高斯噪声	镜像概率 0.5; 噪声方差 0.01

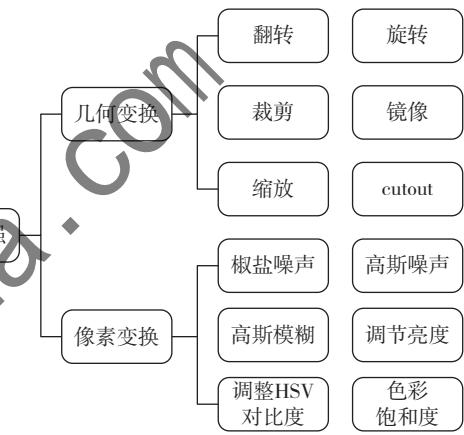


图 9 数据增强策略

## 3 实验及结果分析

### 3.1 实验环境及参数配置

实验使用的 GPU 为英伟达 RTX 4090 显卡、24 GB 显存, 基于 PyTorch 1.13.0 深度学习框架, 操作系统为 Windows 11, 编程语言为 Python 3.11, 利用 CUDA 11.7 进行 GPU 加速。网络训练批量设置为 32, Workers 为 16, 训练轮次均为 200, 图片大小为  $640 \times 640$ , 初始学习率为 0.01。

### 3.2 消融实验

为展示提出算法在复杂电磁环境下对通信终端的识别性能, 本文进行消融实验, 对比分析各种改进策略对性能的影响, 结果如表 3 所示。

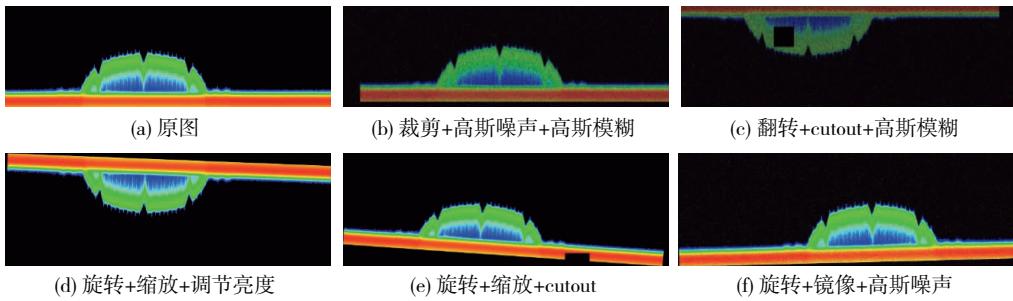


图 10 五个子策略示例图

表 3 消融实验

模型				P/%	R/%	mAP50-95/%	Params/M	GFLOPs
YOLOv8n	DA	C2fCE	PSA					
✓				99.9	100	74.1	3.0	8.1
✓	✓			100	100	76.0	3.0	8.1
✓		✓		100	100	80.0	2.3	6.7
✓			✓	100	99.9	75.4	3.3	8.3
✓	✓	✓		100	100	81.2	2.3	6.7
✓	✓		✓	100	100	76.8	3.3	8.3
✓	✓	✓	✓	100	100	81.5	2.6	6.9

从表 3 结果可以看出: (1) 通过在五个子策略生成的数据集上进行训练, 与 YOLOv8n 原模型相比, mAP50-95 提升 1.9%, 模型的识别精度得到提升。 (2) 所提出的 C2fCE 模块显著优化 YOLOv8n 模型的性能, 降低模型参数量, 从而有效减轻模型的计算负担。 具体来说, 在将 C2fCE 模块集成到 YOLOv8n 模型后, 与原 YOLOv8n 模型相比, GFLOPs 和参数量分别降低 1.4 和 0.7M, mAP50-95 上涨 5.9%。 (3) 引入的 PSA 机制虽然在 mAP50-95 上只提升 1.3%, 但是在测试集上有着较好的识别效果, 提升模型泛化能力。

### 3.3 与其他模型的对比实验

为进一步验证本文所提出的 EMI-YOLO 模型的有效性和可行性, 将 EMI-YOLO 算法与主流目标检测算法 YOLOv5s<sup>[12]</sup>、YOLOv10n<sup>[13]</sup>、YOLOv8n<sup>[14]</sup> 在本文的 CDTR 数据集上进行训练对比, 实验结果如表 4 所示。

由表 4 可以看出, 本文提出的 EMI-YOLO 模型在 mAP50-95 指标上, 相比 YOLOv8n、YOLOv10n 和 YOLOv5s, 分别提高 7.4%、2.3% 和 3.3%。此外, EMI-YOLO 在模型参数量和 GFLOPs 上也是最优, 这证明本文提出的模型能兼顾高精度和轻量化的要求。

不同模型对各个设备的识别性能具体表现如表 5 所示。由表 5 数据可以看到, 相较 YOLOv8n, 本文提出的 EMI-YOLO 模型在 CDTR 数据集上对 nova 9、nova 7 Pro、nova 7 se、Redmi K40、iPhone 11 和 vivo iQOO 设备, mAP50-95 指标分别提升 4.7%、0.5%、3.0%、6.9%、0.0% 和 18%, 可见 EMI-YOLO 模型的特征提取能力更强, 从而可以更精确地对设备进行识别。与 YOLOv10n 相比, EMI-YOLO 对 nova 9 和 iPhone 11 两个设备识别性能稍差, 但 6 个设备的平均识别性能还是 EMI-YOLO 最高。

表 4 不同网络模型在 CDTR 上训练结果

模型	P/%	R/%	mAP50-95/%	Params/M	GFLOPs
YOLOv5s	99.7	100	78.2	7.03	15.8
YOLOv10n	96.3	99.2	79.2	2.7	8.2
YOLOv8n	99.9	100	74.1	3.0	8.1
EMI-YOLO	100	100	81.5	2.6	6.9

表 5 不同网络模型在 CDTR 上各类别 mAP50-95 值 (%)

模型	nova 9	nova 7 Pro	nova 7 se	Redmi K40	iPhone 11	vivo iQOO	平均
YOLOv5s	78.8	77.6	67.4	85.5	68.4	81.3	76.5
YOLOv10n	<b>82.1</b>	78.6	69.0	86.5	<b>72.5</b>	84.5	78.9
YOLOv8n	76.2	79.3	70.2	81.0	72.4	68.5	74.6
EMI-YOLO	80.9	<b>79.8</b>	<b>73.2</b>	<b>87.9</b>	72.4	<b>86.5</b>	<b>80.1</b>

不同网络模型在测试集上的识别准确率如图 11 所示。可以看出, 除在 nova 9 设备上本文提出的 EMI-YOLO 的识别准确率略低于 YOLOv10n 外, 在其他五个通信设备上, EMI-YOLO 的识别准确率都是最高。具体来说, YOLOv8n、YOLOv10n 和 YOLOv5s 三个网络在通信设备上的平均识别准确率分别是 32.8%、51.5% 和 15.8%, EMI-YOLO 模型对 nova 9、nova 7 Pro、nova 7 se、Redmi K40、iPhone 11 和 vivo iQOO 的识别准确率分别为 62%、74%、82%、78%、81% 和 79%, 平均识别准确率为 76%。因此, 上述结果证明 EMI-YOLO 模型在复杂电磁环境下具有较强的抗干扰能力、鲁棒性和优秀的通信终端辐射源识别性能。

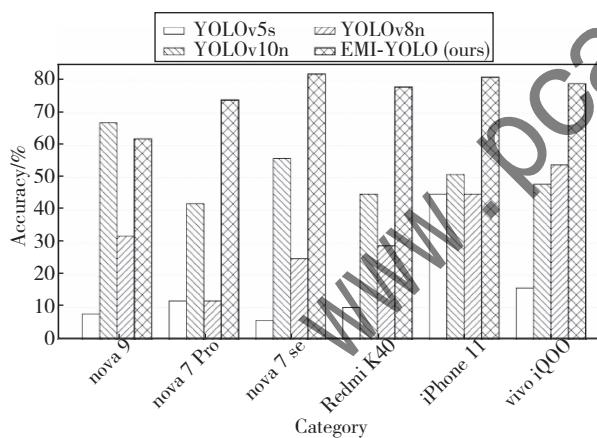


图 11 不同模型对测试集的识别准确率

## 4 结论

本文针对复杂电磁环境下通信设备识别难度大、干扰信号复杂等问题, 提出了一种改进的 EMI-YOLO 算法。在 YOLOv8n 的基础上, 设计 C2fCE 模块以优化特征提取能力, 在主干网络末端引入 PSA 机制以增强全局建模能力, 并结合数据增强策略扩展有限样本空间。通过消融实验和对比实验证所提算法的有效性, 结果表明 EMI-YOLO 在识别精度、计算效率和模型鲁棒性方面均优于 YOLOv8n、YOLOv10n 和 YOLOv5s 等主流算法, 尤其在复杂电磁环境中表现出更强的抗干

扰能力和泛化性能。

尽管取得了较好的实验结果, 本文仍存在一定的局限性。例如, 所用数据集设备类别有限, 采集条件集中于特定频段和场景, 尚未全面验证模型的跨场景适应性。未来工作可从以下两个方向展开: 其一, 在模型设计方面进一步探索轻量化结构与高效注意力机制, 以便在资源受限平台 (如嵌入式设备) 中部署; 其二, 引入跨模态特征融合方法, 将射频信号特征与图像、时频图或环境上下文信息结合, 提高模型对复杂电磁场景的感知与判别能力; 其三, 构建更大规模、多频段、跨场景的开放数据集, 并开展跨域测试, 以系统评估模型在真实环境中的泛化性能。

## 参考文献

- [1] GUI G, LIU M, TANG F, et al. 6G: opening new horizons for integration of comfort, security, and intelligence [J]. IEEE Wireless Communications, 2020, 27 (5): 126–132.
- [2] LU Y, XU L D. Internet of Things (IoT) cybersecurity research: a review of current research topics [J]. IEEE Internet of Things Journal, 2018, 6 (2): 2103–2115.
- [3] ZHANG W, LIU L, JIANG Y, et al. A specific emitter identification method based on dual neural networks [C]//2024 IEEE 12th Asia-Pacific Conference on Antennas and Propagation. IEEE, 2024: 1–2.
- [4] 熊永坤. 电子装备复杂电磁环境适应性评估指标体系研究 [J]. 舰船电子工程, 2020, 40 (9): 167–171.
- [5] HUANG H, GUO S, GUI G, et al. Deep learning for physical-layer 5G wireless techniques: opportunities, challenges and solutions [J]. IEEE Wireless Communications, 2019, 27 (1): 214–222.
- [6] DELLEJI R, SLIMENI I. RF-YOLO: YOLOv8 based model for efficient drone detection and classification in wireless communication [J]. PeerJ Computer Science, 2025, 11: e2545.
- [7] LI Q. YOLOv5s-CWMDSQ: an improved YOLOv5s algorithm for modulation recognition of communication signals [J]. Wireless Communications and Mobile Computing, 2024, 2024: 1–13.
- [8] Liu Shu, Qi Lu, Qin Haifang, et al. Path aggregation network for instance segmentation [C]//2018 IEEE Conference on Computer Vision and Pattern Recognition, Salt Lake City, UT, USA, 2018:

- 8759 – 8768.
- [9] 李坡, 刘万全, 宿绍莹, 等. 数字荧光技术在电子侦察中的应用 [J]. 电子测量与仪器学报, 2008, 22 (S2): 342 – 346.
- [10] 郭仕剑, 唐鹏飞, 宿绍莹, 等. 数字荧光实时频谱分析设备的设计实现 [J]. 电子测量与仪器学报, 2011, 25 (9): 781 – 786.
- [11] SHORTEN C, KHOSHFTAAR T M. A survey on image data augmentation for deep learning [J]. Journal of Big Data, 2019, 6 (1): 1 – 48.
- [12] JIANG L, LIU H, ZHU H, et al. Improved YOLOv5 with balanced feature pyramid and attention module for traffic sign detection [C]//MATEC Web of Conferences. EDP Sciences, 2022, 355: 03023.
- [13] WANG A, CHEN H, LIU L, et al. YOLOv10: real-time end-to-end object detection [J]. Advances in Neural Information Processing Systems, 2024, 37: 107984 – 108011.
- [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 (ADICS). IEEE, 2024: 1 – 6.

(收稿日期: 2025 – 07 – 24)

#### 作者简介:

张策 (1991 – ), 男, 本科, 工程师, 主要研究方向: 目标识别算法。

苏思雨 (2002 – ), 女, 硕士, 主要研究方向: 人工智能、目标识别算法。

## “数据基础设施建设与运营”主题专栏征稿启事

数据基础设施是数字经济时代的关键战略性底座, 其建设水平与运营能力直接关系到国家数字竞争力与社会数字化转型的深度。为深入探讨数据基础设施建设的前沿理论、技术路径、政策机制与实践挑战, 凝聚跨学科学术智慧, 本刊拟在 2026 年第 4 期推出“数据基础设施建设与运营”主题专栏, 旨在汇聚学术界与产业界的前沿思想与最佳实践, 探索数据基础设施建设从技术架构到价值运营的系统性路径, 推动该领域的理论创新与实践发展。现诚挚邀请相关领域的专家学者、科研人员踊跃投稿!

### 一、征文主题: 数据基础设施建设与运营

包括但不限于以下学术方向:

1. 一体化大数据中心新型体系架构;
2. 可信数据空间基础架构与核心组件研究;
3. 算力网络、智能计算中心、边缘计算等新型算力基础设施;
4. 基于区块链的数据溯源与审计机制;
5. 隐私增强技术;
6. 数据空间、隐私计算、区块链在基础设施层的集成方案;
7. 基础设施自动化运维与安全韧性技术;
8. 重点行业数据基础设施建设;
9. 数据基础设施应用效能的综合评价指标体系。

### 二、投稿要求

1. 稿件请用 word 格式录入, 并套用本刊投稿模板。模板下载网址: [http://files.chinaaet.com/files/Periodical/pcachina\\_Templates.doc](http://files.chinaaet.com/files/Periodical/pcachina_Templates.doc)。

2. 投稿文章须未在其他期刊或者出版正式论文集的会议上刊登过, 且不在其他刊物或会议的审稿

过程中, 不存在一稿多投现象。

3. 文章无抄袭、剽窃、侵权、虚假引用等不良学术行为, 且不违反相关法律法规, 不涉及国家、企业秘密, 稿件文责自负。

4. 论文要求观点鲜明、逻辑严谨、论据充分、方法合理, 字数在 5000 ~ 8000 字。

5. 请在官方投稿网站 (<http://www.pcachina.com>) 注册、投稿。注册后请投稿在“主题专栏”栏目。稿件经评审合格录用后, 在《网络安全与数据治理》2026 年第 4 期 (正刊) 以主题专栏形式发表。

### 三、时间安排

截稿日期: 2026 年 3 月 1 日

审稿反馈日期: 2026 年 3 月 15 日

出刊日期: 2026 年 4 月 15 日

### 四、联系方式

联系人: 牟老师 (010-82306116)

郝老师 (13811792199)

邮 箱: [muyx@chinaaet.com](mailto:muyx@chinaaet.com)

《网络安全与数据治理》编辑部

2026 年 1 月

## 版权声明

凡《网络安全与数据治理》录用的文章，如作者没有关于汇编权、翻译权、印刷权及电子版的复制权、信息网络传播权与发行权等版权的特殊声明，即视作该文章署名作者同意将该文章的汇编权、翻译权、印刷权及电子版的复制权、信息网络传播权与发行权授予本刊，本刊有权授权本刊合作数据库、合作媒体等合作伙伴使用。同时，本刊支付的稿酬已包含上述使用的费用，特此声明。

《网络安全与数据治理》编辑部