

doi: 10.7690/bgzdh.2026.06.013

# 基于 YOLOv5-STE 的海面雷达 RD 图像舰船目标识别算法

杨 剑, 魏艺楷, 董孟琛, 李传祥

(火箭军工程大学导弹工程学院, 西安 710025)

**摘要:** 针对雷达舰船在强干扰下目标识别变得更加困难的问题, 提出一种基于 YOLOv5 的改进模型以提升对舰船目标和无源干扰的检测精度和适应性。通过在 YOLOv5 模型中增加针对小目标的检测层, 优化了原始网络, 其目的是增强对小目标的检测准确性, 确保在复杂海洋环境中更有效地识别目标舰船; 由于集成了高效多尺度注意力机制(exponential moving average, EMA), 不仅可以减轻海洋噪声和复杂背景的影响, 而且可以使得模型在识别中具有更强的特征表达能力, 从而提高算法识别性能。利用无源干扰环境下的舰船 RD 图像数据集进行了实验验证。实验结果表明: 该改进方法在 RD 数据集上取得了较好的目标识别性能, 有效提高了目标识别的准确度。

**关键词:** 深度学习; 小目标检测层; 注意力机制; YOLOv5

**中图分类号:** TP274+.5 **文献标志码:** A

## Ship Target Recognition Algorithm Based on YOLOv5-STE in Radar RD Image of Sea Surface

Yang Jian, Wei Yikai, Dong Mengchen, Li Chuanxiang

(College of Missile Engineering, Rocket Force University of Engineering, Xi'an 710025, China)

**Abstract:** Aiming at the problem that it is more difficult for radar to recognize ship targets under strong jamming, an improved model based on YOLOv5 is proposed to improve the detection accuracy and adaptability of ship targets and passive jamming. The original network is optimized by adding a detection layer for small targets in the YOLOv5 model, which aims to enhance the detection accuracy of small targets and ensure more effective recognition of target ships in complex marine environments; Due to the integration of the exponential moving average (EMA) mechanism, it can not only reduce the impact of ocean noise and complex background, but also make the model have stronger feature expression ability in recognition, thus improving the recognition performance of the algorithm. The experimental verification is carried out by using the ship RD image data set in the passive jamming environment. The experimental results show that the improved method achieves better target recognition performance on RD data sets, and effectively improves the accuracy of target recognition.

**Keywords:** deep learning; small target detection layer; attention mechanism; YOLOv5

## 0 引言

雷达技术, 作为海事监控的核心工具, 对海上安全和海洋资源的管理扮演了关键角色。在复杂的海洋环境中, 雷达系统在进行海上目标识别时面临诸多挑战, 特别是以角反射体为代表的无源干扰, 当雷达波照射时, 角反射体会对产生的电磁波进行折射和放大, 变成很强的雷达回波信号, 易使雷达接收机误将其认作舰艇, 最终导致军事误判; 因此, 研究精确识别海上舰船和无源干扰的检测算法对现代军事战略具有重要意义。

文献[1]提出改进后的 YOLOv5 算法, 通过引入坐标注意机制和双向特征金字塔网络, 有效提高了水上船舶检测精度。文献[2]基于 YOLOv5s 提出的一种小型船舶检测模型, 引入混合空间金字塔池和

协调注意机制。文献[3]提出一种基于 YOLOv5n 的轻量级目标检测算法, 改进后的算法压缩了模型体积且提高了目标检测精度。文献[4]针对舰船目标识别问题, 提出一种基于 YOLOv5 的轻型舰船检测算法, 实现了实时舰船目标识别。文献[5]提出一种基于 YOLOv5 的改进定向舰船检测方法: 首先, 对 SAR 船舶检测数据集进行重新标定, 有效提高探测器的检测性能; 其次, 采用拼接方法对数据集进行增强, 并对损失函数进行修正, 提高模型性能; 此外, 在 YOLOv5 检测网络中应用了圆形光滑标签旋转检测算法, 实现了舰船目标的精确定位。文献[6]将旋转锚框目标检测运用到 SAR 图像检测, 与最新的检测算法和卫星遥感大数据相结合, 运用最新的 Swim-transformer 模型, 提出一种 Augmix 方法的

收稿日期: 2024-12-08; 修回日期: 2025-01-20

基金项目: 国家自然科学基金(62071481)

第一作者: 杨 剑(1980—), 男, 四川人, 博士。

改进版，并对数据进行增强，且御用自注意力机制，将其加入到 YOLOv3 网络框架。文献[7]提出一种无人机载高分辨率 SAR 图像目标快速检测方法，实验结果表明，该方法不仅可以提升对高分辨率 SAR 图像目标的检测效率，改善 SAR 图像目标提取能力，而且有利于发现部分人工方法容易遗漏的小目标。文献[8]利用数据增强和特征增强的学习机制，在扩充样本数据集的同时增强目标特征的显著性。通过定性和定量的实验结果分析，在相关数据集上，该方法可在不增加过多计算成本的基础上提升分割准确率。由于合成孔径雷达本身的光学特性以及图像采集过程中的噪声干扰，SAR 图像存在着类别不平衡等问题，文献[9]研究不平衡 SAR 图像的识别技术，从 SAR 图像特点出发，结合深度学习算法，建立不平衡 SAR 图像的快速识别模型，具有重要的应用价值。文献[10]根据炸点、风轮机与气象杂波目标都具有多普勒频谱展宽的特点，在回波预处理过程中提取目标回波频谱，最后以支持向量机对 3 类目标实现分类识别，基于实测数据的分类识别结果表明，本文中的 3 类特征对各类目标的分类都具有有效性。文献[11]提出了一种基于多浮标观测的

目标线谱多普勒变化规律和目标通过特性的多浮标联合定位算法，利用多普勒变化规律，同时解算出目标的定位点、航速、航向，最后通过实验数据对模型进行了验证。文献[12]利用距离-多普勒演化对多普勒和距离信息进行分析，并从距离-多普勒演化中提取多普勒特征，在 LabVIEW 中生成多普勒谱图。分析后区分驾驶员警觉性较低的背屈颈部运动与其他驾驶员头颈部运动的多普勒和距离特征，实验证明了基于雷达的头部运动检测作为驾驶员监控解决方案的可靠性。

深度学习技术在飞速发展，其在图像识别、目标检测等领域展现出强大的能力。笔者基于海面舰船的应用场景，在 YOLOv5s 算法的基础上提出一种改进的适用于海上舰船 RD 图的目标识别检测方法。

### 1 基于改进的 YOLOv5 智能识别算法

#### 1.1 YOLOv5 算法及其结构

如图 1 所示，YOLOv5 算法的结构流程主要包括 4 个主要部分：输入端、主干网络、Neck 网络和 Head 输出端。

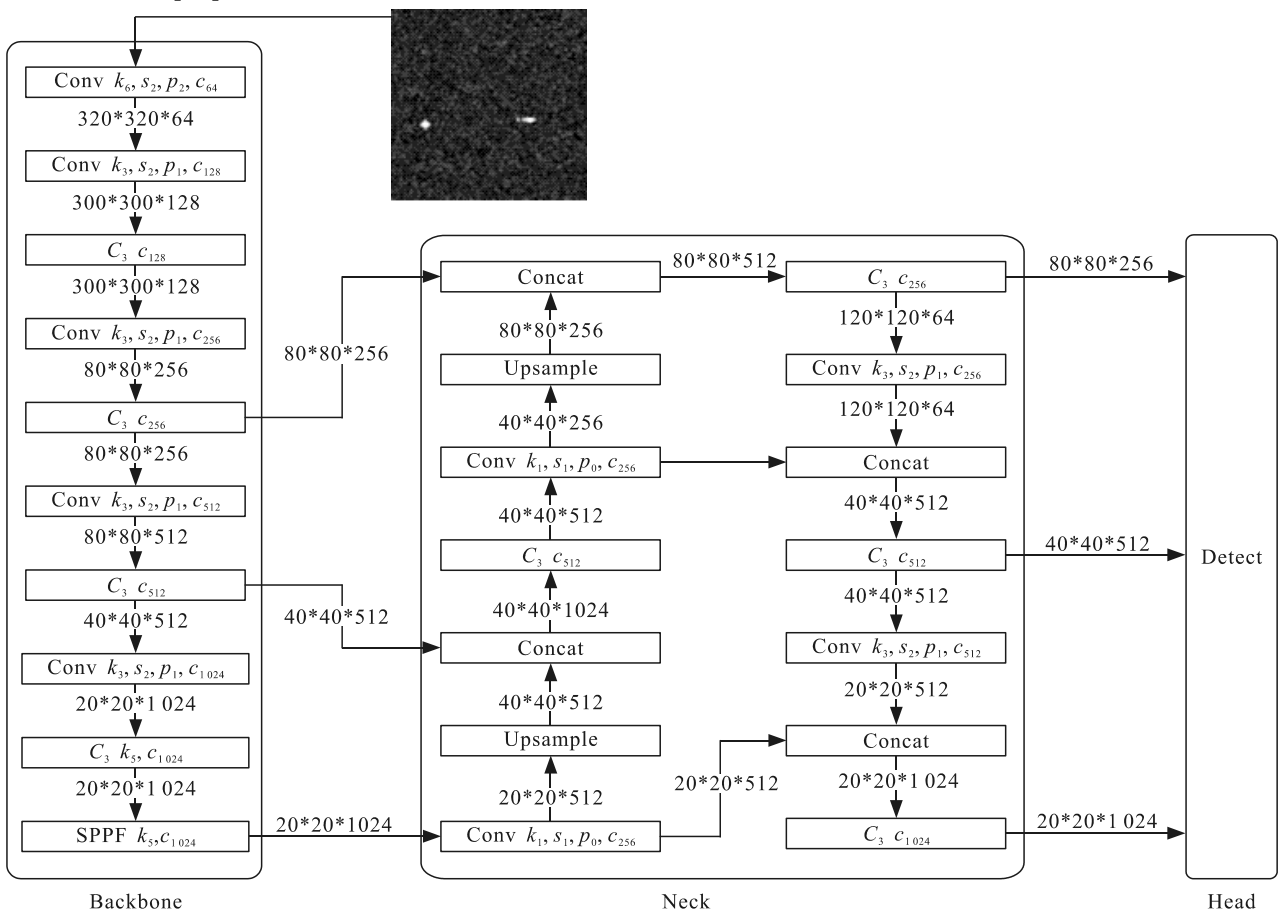


图 1 YOLOv5 原始结构

YOLOv5 的输入层首先将图像进行尺寸调整和归一化，以满足模型输入的要求；其次，其传输至后续卷积网络，用于多尺度目标特征提取和检测。

主干网络是 YOLOv5 的重要部分，用于提取图像的特征。YOLOv5 采用了 CSPDarknet53 和 Focus 结构作为主干网络。其中，Focus 结构将输入复制 4 份，然后通过切片操作将其分为 4 个切片，接着通过 Concat 层将这些切片进行拼接。

Neck 网络是连接主干网络和 Head 输出端的中间部分，用于进一步增强特征的多样性和鲁棒性。YOLOv5 中的 Neck 网络采用了空间金字塔池化结构模块和特征金字塔+路径聚合网络模块。SPP 模块通过空间金字塔池化操作来增强特征表示，捕捉多尺度信息。而 FPN+PAN 模块则负责将不同层级的特征图进行上采样和连接，实现多尺度特征的融合，提升检测性能。

Head 输出端是神经网络后期的组件，主要负责整合和解码来自网络中不同尺度特征图的信息。这些特征图包含目标的位置、类别和置信度等信息。Head 部分通过多尺度特征融合、预测框解码及应用损失函数优化目标检测性能，最终生成检测结果，实现实时、快速和准确的目标检测。

### 1.2 YOLOv5 改进算法

笔者依据实际图像尺寸进行分析，将像素尺寸小于 32×32 的目标物体为小目标。在雷达的目标检测中，小目标样本相对于明显的大目标样本更容易出现误检和漏检，导致检测效果差距较大；因此，有必要寻求改进方法来提高模型对小目标的检测效果。

笔者对雷达多普勒频移图的特性分析后，提出利用增加小目标检测层和 EMA 注意力机制的方法改进原有的 YOLOv5 算法，增加的小目标检测层对较浅的特征图与较深的特征图进行拼接后再进行检测，使算法更专注于检测小目标图；增加的 EMA 注意力机制可以减少计算复杂度和内存占用，同时保持注意力机制优化特征表示，提高舰船和无源干扰检测性能。

#### 1.2.1 增加小目标检测层

由于目标检测需要依赖高层语义信息与底层细节信息，特征融合难以显著提升其检测精度；因此，笔者选择增加小目标检测层，并将其加入到 YOLOv5s 算法中，以提升对于小目标的检测性能。

原始 YOLOv5s 算法在检测部分有 3 个检测层，利用  $P_3$ 、 $P_4$  和  $P_5$  分别进行 8 倍、16 倍和 32 倍下采样得到的特征图来检测目标，但是由于像素尺寸小于 8×8 的小目标，很容易出现漏检的现象；因此，笔者增加了  $P_2$  小目标检测层，在 19 层之后增加上采样，扩大特征图，将 20 层经上采样获得的 160×160 的特征图与主干网络中的特征图进行融合，最终得到 4 个尺寸的检测层，这使得增强后的检测模型能够检测到尺寸最低为 4×4 的小目标。

#### 1.2.2 高效多尺度注意力机制

笔者采用一种高效多尺度注意力机制，如图 2 所示。通过对 YOLOv5s 模型的特征图进行加权平均来提取特征信息。具体来说，EMA 注意力机制通过引入一个权重因子来调整特征图中每个位置的重要性，从而使模型能够更好地关注 RD 数据集图像中的重要特征。

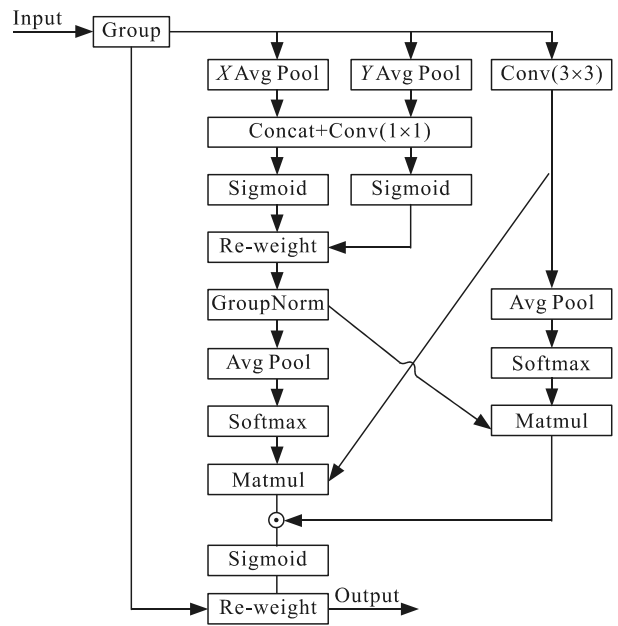


图 2 EMA 注意力机制结构

在海洋的复杂背景下，舰船和无源干扰在雷达的识别中不易区分识别，插入 EMA 机制模块有助于关注重要特征，降低复杂背景中的干扰，提高检测准确性，并且可以帮助缓解参数的剧烈变动，降低过拟合的风险，加速收敛，并提高泛化能力。其具体操作如下：

- 1) 更新权重策略。EMA 机制将模型参数的更新从每次仅依据梯度调整改为依据历史累积的指数移动平均进行调整。这使得模型参数在一个滑动窗口内的修改更为平缓，从而提高稳定性。
- 2) 指数移动平均计算。对于模型的某个参数  $w$

以及当前步的更新值(如利用梯度下降法计算的)  $w_{new}$ , EMA 更新参数:

$$w_{EMA} = 1 - decay\_rate * w + decay\_rate * w_{new} \quad (1)$$

式中  $decay\_rate$  为一个介于 0~1 的衰减系数,用于控制平滑程度。较大的  $decay\_rate$  意味着对历史参数的依赖更强,更新速度较慢;较小的  $decay\_rate$  则表示对历史参数的依赖较弱,过程变得灵活但容易引起参数抖动。

3) 模型收敛和验证。EMA 机制使得模型收敛速度加快且更为稳定。训练过程中,EMA 参数会持续更新,但不会应用于计算预测结果的网络中。在

验证阶段,通常会使用 EMA 参数代替原始模型参数,以评估模型的泛化能力。使用 EMA 参数的模型往往在验证集上表现更好,因为它可以平滑模型在训练过程中的噪声。

本文中的增加注意力机制的改进是将 EMA 机制模块添加在主干层中  $C_3$  模块后和 SPPF 模块前。在此处添加,有助于在特征金字塔融合前对特征进行优化,有效捕捉高层语义信息,保留部分底层细节信息,同时降低计算负担,提升整体网络训练和优化效果。最终, YOLOv5s 改进后的网络结构如图 3 所示。

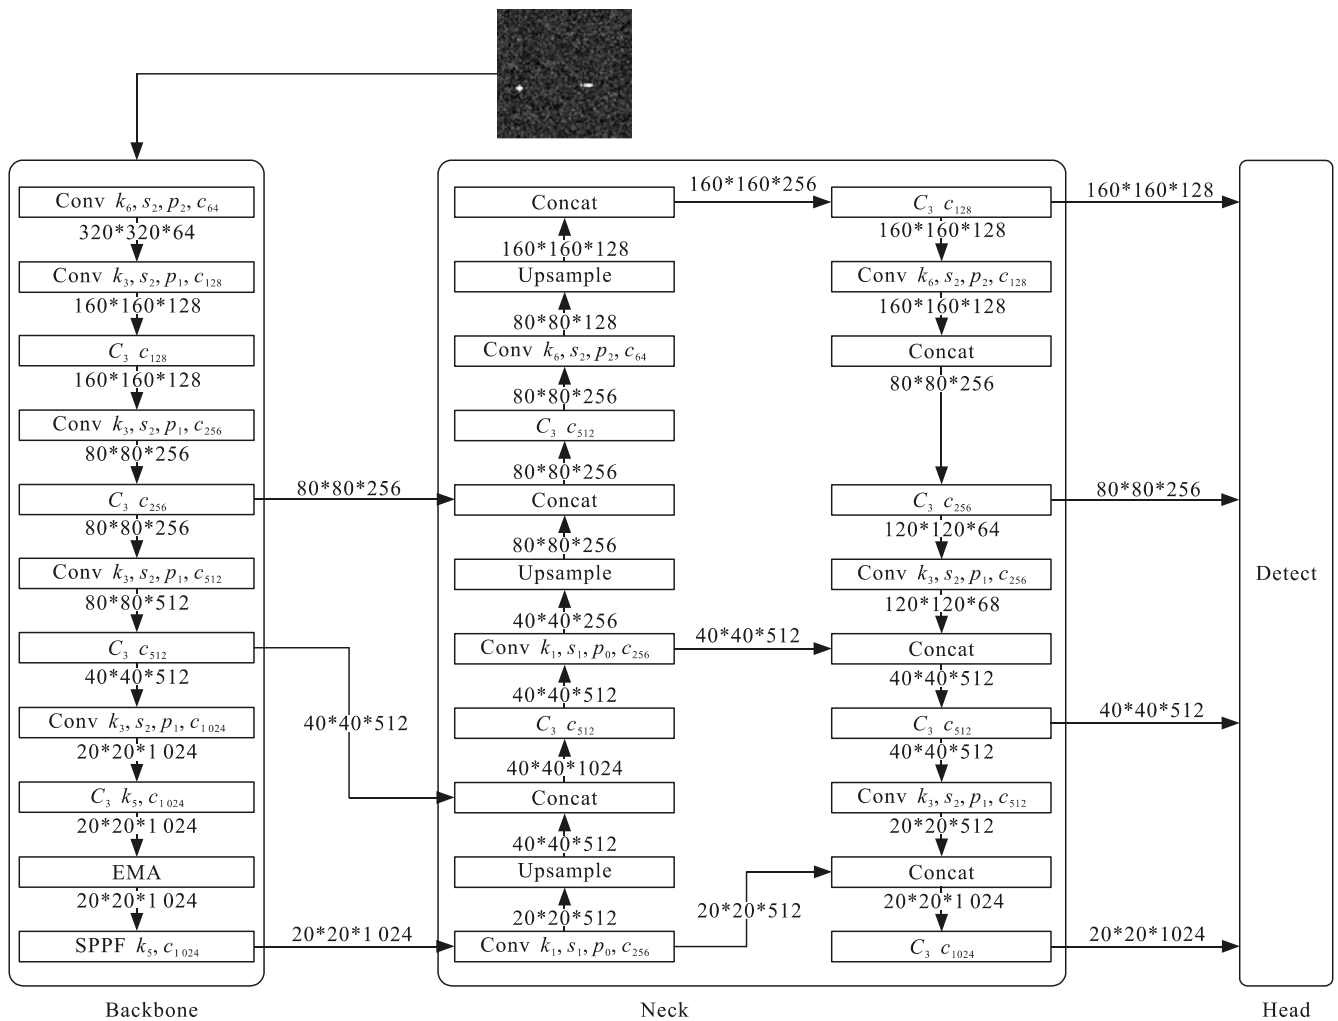


图 3 改进后 YOLOv5s 结构

## 2 实验验证及结果分析

### 2.1 数据集及评价指标

笔者使用的数据集来源于一个在无源干扰环境下的海面 RD 图像。由于原始回波数据生成的图像分辨率为 64\*1024,较大的长宽比可能会对训练产生较大影响;因此,笔者通过裁剪和填充,将分辨

率调整为 320x320 的 RD 图像。最终,数据集总计 9600 余个实例。本实验按照 8:2 的比例将数据集划分为训练集和测试集。

评价指标为:  $mAP_{50}$ 、 $mAP_{50:95}$ 、精确率 (Precision, P)、召回率 (Recall, R)、Parameter 作为模型性能的评价指标,  $mAP_{50}$  为 IoU 阈值为 0.5 时所有目标类别的平均检测精度,  $mAP_{50:95}$  代表以

步长为 0.05 时, 计算 IoU 阈值从 0.5~0.95 的所有 10 个 IoU 阈值下的检测精度的平均值。Parameter 代表模型的参数量, 用于衡量内存资源的消耗。

$$AP = \int_0^1 PdR ; \tag{2}$$

$$mAP = \sum_{i=1}^N AP_i / N ; \tag{3}$$

$$Precision = TP / (TP + FP) ; \tag{4}$$

$$Recall = TP / (TP + FN) 。 \tag{5}$$

## 2.2 实验验证

### 2.2.1 条件设置

操作系统为 Ubuntu20.04, 实验的软件环境为 Pytorch1.9, CUDA11.2 和 CUDNN8.2.1, 使用 GPU (2 片 Nvidia GeForce RTX A6000) 进行训练。网络模型训练阶段, 在相同超参数下 (不一定最优) 进行训练和测试。其中迭代批量 (batch-size) 大小为 16, 总迭代数设置为 200 个 Epoch, 初始学习率设置为 0.1。

### 2.2.2 实验对比及分析

为探究改进措施对实验的影响, 笔者在相同实验环境下进行实验, 涉及 YOLOv5s、YOLOv5s\_SmallTarget (添加小目标检测层)、YOLOv5s\_EMA (增加 EMA 注意力机制) 和 YOLOv5s\_STE (引入 2 种改进)。实验分析如表 1 所示。

表 1 对舰船识别的实验结果

算法	P	R	mAP <sub>50</sub>	mAP <sub>50:95</sub>
YOLOv5s	0.846	0.710	0.841	0.450
YOLOv5s_SmallTarget	0.801	0.755	0.852	0.477
YOLOv5s_EMA	0.883	0.763	0.812	0.494
YOLOv5s_STE	0.822	0.864	0.878	0.525

根据表 1 的结果可以得出: YOLOv5s\_EMA 在识别舰船上, 精确率 P 提升 3.7%; 对于召回率 R, YOLOv5s\_SmallTarget 和 YOLOv5s\_EMA 均比 YOLOv5s 要高出 5% 以上, YOLOv5s\_STE 的提升更是高达 16.3%, 表明该算法对舰船的识别更加精准; 同时引入 2 种改进算法, 对于舰船的识别在召回率、mAP<sub>50</sub>、mAP<sub>50:95</sub> 均表现出更优异的性能, 如表 2—3 所示。

表 2 对无源干扰识别的实验结果

算法	P	R	mAP <sub>50</sub>	mAP <sub>50:95</sub>
YOLOv5s	0.719	0.951	0.912	0.400
YOLOv5s_SmallTarget	0.751	0.933	0.915	0.405
YOLOv5s_EMA	0.804	0.934	0.823	0.438
YOLOv5s_STE	0.873	0.865	0.927	0.415

根据表 2 可知: 引入 2 种改进的精确率 P 均有不同程度的提升, 分别为 3.2%、8.5%, 同时引入提

升效果提升高达 15.4%, 表明在精度方面的有效性, 说明对于无源干扰的识别更加精准。

表 3 数据集实验结果

算法	P	R	mAP <sub>50</sub>	mAP <sub>50:95</sub>	Parameters
YOLOv5s	0.783	0.826	0.877	0.425	7.016×10 <sup>6</sup>
YOLOv5s_SmallTarget	0.806	0.845	0.884	0.441	7.159×10 <sup>6</sup>
YOLOv5s_EMA	0.843	0.848	0.897	0.466	7.057×10 <sup>6</sup>
YOLOv5s_STE	0.847	0.865	0.902	0.468	7.210×10 <sup>6</sup>

根据表 3 可知: 在舰船和无源干扰均存在的数据集中, 对于精确度 P, 只引入 EMA 注意力机制和同时引入 2 种改进的提升都比较高, 分别提升 6%、6.3%, 表明 EMA 注意力机制会对海面环境中无源干扰进行高效过滤; 对于召回率 R, 只引入小目标检测层或添加 EMA 注意力机制, 提升效果不相上下, 大约在 2% 左右, 但 2 种改进均引入后, 效果提升 3.9%; 对于 mAP<sub>50:95</sub>, 同时引入改进的提升最高, 提升 4.3%。

综上所述, YOLOv5s 作为基础算法, 其在舰船和无源干扰检测上取得了不错的结果, 但对于改进, 仍有不足之处。添加小目标检测层相较于 YOLOv5s 算法, 改进了对小目标的识别, 整体表现略有提升。引入 EMA 注意力机制后, 模型在各项指标上都有显著提升, 表明注意力机制能有效优化特征表示, 提高检测性能。引入 2 种改进之后, 相较于分别引入单个改进或者原始 YOLOv5s 算法模型, 总体表现在近乎所有指标上都更有优势, 尤其是对于舰船的召回率提升高达 16.3%, 对于无源干扰的精确率提升高达 15.4%, 且在其他指标上也有较大的提升。

## 3 结论

笔者在 YOLOv5s 算法的基础上提出一种改进的适用于海上舰船 RD 图的目标识别检测方法, 达到提高对于舰船和无源干扰的准确率的目的。

从实验结果来看: 相比原模型, 该方法在舰船的识别上, 召回率提升 16.3%; 在无源干扰的识别上, 精确率提升 15.4%; 在 mAP<sub>50</sub>、mAP<sub>50:95</sub> 上也有部分提升, 且模型参数量无较大变化, 表明同时引入 2 种改进对于模型的各方面指标均有良好的提升效果。

## 参考文献:

[1] ZHANG A L, ZHU X. Research on ship target detection

- based on improved YOLOv5 algorithm[C]//2023 5th International Conference on Communications, Information System and Computer Engineering (CISCE). Piscataway: IEEE, 2023: 459-463.
- [2] LIU Z H, ZHANG W J, YU H, et al. Improved YOLOv5s for Small Ship Detection with Optical Remote Sensing Images[J]. IEEE Geoscience and Remote Sensing Letters, 2023, 20: 1-5.
- [3] ZHAO X M, SONG Y L, SHI S X, et al. Improving YOLOv5n for lightweight ship target detection[C]//2023 IEEE 3rd International Conference on Computer Systems (ICCS). Piscataway: IEEE, 2023: 110-115.
- [4] SUN Y, CAI C T, LI M T. A Lightweight Ship Detection Algorithm Based on YOLOV5[C]//2022 China Automation Congress (CAC). Piscataway: IEEE, 2022: 3739-3743.
- [5] SUN Z Z, LEI Y, LENG X G, et al. An improved oriented ship detection method in high-resolution SAR image based on YOLOv5[C]//2022 Photonics & Electromagnetics Research Symposium (PIERS). Piscataway: IEEE, 2022: 647-653.
- [6] 李心宇. 基于深度学习的 SAR 图像舰船目标检测[D]. 烟台: 烟台大学, 2023.
- [7] 王中宝, 尹奎英. 一种无人机电载高分辨率 SAR 图像目标快速检测方法[J]. 指挥控制与仿真, 2023, 45(5): 43-50.
- [8] 赵维谚, 沈志, 徐真, 等. 基于增强学习机制的 SAR 图像水域分割方法[J]. 计算机应用与软件, 2023, 40(5): 262-265, 337.
- [9] 向诚, 颜世杰, 桂玲. 不平衡 SAR 图像舰船目标识别模型[J]. 舰船科学技术, 2023, 45(5): 174-177.
- [10] 潘慧冲, 罗丁利, 徐保庆. 基于多普勒频谱特性的雷达目标分类识别研究[J]. 火控雷达技术, 2023, 52(2): 50-55.
- [11] 樊敏, 李洪道, 白鹏. 一种基于多浮标线谱多普勒频移特征的联合定位算法研究[J]. 声学与电子工程, 2023, (4): 8-11.
- [12] CHAE R, WANG A, LI C Z. FMCW radar driver head motion monitoring based on Doppler spectrogram and range-Doppler evolution[C]//2019 IEEE Topical Conference on Wireless Sensors and Sensor Networks (WiSNet). Piscataway: IEEE, 2019: 1-4.

\*\*\*\*\*  
(上接第 47 页)

采用本文中叙述的多参数压差传感器进行测量时, 将 0~8 kPa 压力传感器和 0~80 kPa 压力传感器集成在一起后, 当测量压力为 3 kPa 时, 计算传感器 A 的相对值为 0.375, 传感器 B 的相对值为 0.037 5, 采用 A 传感器的值作为输出值, 精度为 8 Pa; 当测量压力为 20 kPa 时, 计算传感器 A 的相对值为 2.5, 大于 1.2 去掉, 传感器 B 的相对值 0.25, 采用 B 传感器的值作为输出值, 解决了测量精度和测量量程间的矛盾, 实现了高精度、大量程的测量效果。

## 5 结束语

笔者通过对多参数融合智能工业传感器集成技术和量程自适应选择算法的研究, 实现了大量程、高精度差压流量仪表的数据检测端设计。在此基础

上研制了基于 FF 现场总线的智能通信卡, 可实现远距离通信、总线供电和仪表数字化的改造, 可广泛应用于石油化工、精细化工等领域。

## 参考文献:

- [1] 张永胜, 张毅治, 刘彦军. 差压式流量计测量脉动流量方法研究[J]. 计量学报, 2020, 41(4): 430-433.
- [2] 李强, 梁莉, 刘桢, 等. 具有温度补偿功能的智能压力传感器系统[J]. 仪器仪表学报, 2008, 29(9): 1934-1938.
- [3] 邓细平, 吴小根. FF 现场总线在工业过程控制系统中的应用[J]. 有色冶金设计与研究, 2019(5): 29-30.
- [4] 叶宁, 杜策, 李启峰, 等. 基于 FF 型总线标准化功能块的应用分析[J]. 电工技术, 2021(15): 116-118.
- [5] 郝彩哲, 宋晓明, 王东, 等. 对称多孔孔板差压式流量计计量性能试验研究[J]. 电子测量与仪器学报, 2020, 34(5): 174-180.