

基于渐近式特征融合的轻量化 SAR 舰船检测算法

刘飞宇,张静*,王亦楠

(中北大学软件学院,山西太原 030051)

摘要:针对合成孔径雷达(synthetic aperture radar, SAR)舰船检测中现有模型感受野受限、多尺度特征融合低效及计算复杂度高的问题,提出通道聚合特征金字塔网络(channel-aggregated feature pyramid network, CA-FPN)。在特征金字塔架构层面,构建跨层级动态加权特征融合机制,通过可学习通道注意力权重自适应校准多分辨率特征,克服传统渐近式特征金字塔(asymptotic feature pyramid network, AFPN)固定采样约束,显著提升多尺度目标表征能力;在特征提取单元设计上,提出并行多尺度空洞卷积模块(parallel multi-scale dilated convolution block, PDBlock)、集成通道注意力(squeeze-and-excitation, SE)与空洞卷积技术,通过特征通道聚合门控机制有效缓解多尺度特征融合过程中的语义冲突。SSDD 和 LS-SSDD 标准数据集上试验评估表明:相较基准模型 AFPN, CA-FPN 在保持检测精度前提下,模型参数量由 1.93×10^6 降至 1.17×10^6 (降幅 39%), 计算复杂度 G_{FLOPs} 从 4.24 降至 3.19 (降幅 24%), SSDD 和 LS-SSDD 数据集上平均精度分别提升 2.8% 和 3.5%, CA-FPN 更适应 SAR 舰船目标检测任务。

关键词:合成孔径雷达;舰船检测;多尺度;跨层级特征融合;注意力机制;空洞卷积

中图分类号:TP183;TN957.52 **文献标志码:**A

引用格式:刘飞宇,张静,王亦楠. 基于渐近式特征融合的轻量化 SAR 舰船检测算法[J]. 山东大学学报(工学版), 2026, 56(2):52-59.

LIU Feiyu, ZHANG Jing, WANG Yinan. Lightweight SAR ship detection algorithm based on asymptotic feature fusion[J]. Journal of Shandong University (Engineering Science), 2026, 56(2):52-59.

Lightweight SAR ship detection algorithm based on asymptotic feature fusion

LIU Feiyu, ZHANG Jing*, WANG Yinan

(School of Software, North University of China, Taiyuan 030051, Shanxi, China)

Abstract: To address the limitations of restricted receptive fields, inefficient multi-scale feature fusion, and high computational complexity in existing synthetic aperture radar (SAR) ship detection models, a channel-aggregated feature pyramid network (CA-FPN) was proposed. At the feature pyramid architecture level, a cross-level dynamically weighted feature fusion mechanism was introduced. This mechanism adaptively calibrated multi-resolution features using learnable channel attention weights, which overcame the fixed sampling constraints of the traditional asymptotic feature pyramid network (AFPN) and significantly enhanced multi-scale target representation. In designing the feature extraction unit, a parallel multi-scale dilated convolution block (PDBlock) was developed. By integrating the squeeze-and-excitation (SE) channel attention mechanism with dilated convolution techniques, and employing a feature channel aggregation gating mechanism, the PDBlock effectively mitigated semantic conflicts during multi-scale feature fusion. Experimental evaluations on the standard SSDD and LS-SSDD datasets demonstrated that, compared to the baseline AFPN model, CA-FPN maintained detection accuracy while reducing model parameters from 1.93×10^6 to 1.17×10^6 (a 39% reduction) and computational complexity (in G_{FLOPs}) from 4.24 to 3.19 (a 24% reduction). The mean average precision increased by 2.8% on SSDD and 3.5% on LS-SSDD. CA-FPN was more effective and better adapted to the requirements of SAR ship target detection tasks.

Keywords: synthetic aperture radar; ship detection; multi-scale; cross-level feature fusion; attention mechanism; dilated convolution

0 引言

合成孔径雷达 (synthetic aperture radar, SAR) 舰船检测旨在通过处理 SAR 遥感图像,自动识别和精确定位海洋场景中舰船目标^[1],是遥感图像分析领域的研究热点之一。但海洋背景复杂、目标尺度多样、部署资源受限等挑战,给 SAR 舰船检测带来很大困难^[2]。近年来,深度学习模型被广泛用于 SAR 舰船检测,高性能模型不断涌现^[3]。目前主要有基于 Transformer 模型的方法^[4]和基于卷积神经网络(convolutional neural network, CNN)的两种方法^[5]:前者通过自注意力机制获得全局上下文建模能力,将 SAR 图像分割为序列化图像块进行特征交互;后者依托卷积操作的局部感知特性,逐层堆叠卷积核提取舰船目标的纹理、边缘等局部特征。将注意力机制嵌入 CNN 架构已成为一种主流方法,可显著提升小目标与密集舰船的定位精度。例如文献[6]通过自设计骨干网络和网络剪枝减少存储和计算量;文献[7]提出轻量化网络 L-ENet 增强信息融合和检测效率;文献[8]设计多尺度融合头模块提升特征融合效果;文献[9]提出 VS-LSDet 引入 Ghost 卷积减少网络参数;文献[10]提出基于权重剪枝的模型压缩方法去除冗余参数。不过,这些方法只是简单合并从不同尺寸提取的多种特征,未考虑特征融合中其他层中大量无关信息的潜在集成。文献[11]提出渐近特征金字塔网络 (asymptotic feature pyramid network, AFPN),维持高分辨率表示形式,利用自适应空间融合操作过滤特征并保留有用信息进行融合。基于此,本研究在 AFPN 结构

基础上提出一种通道聚合特征金字塔网络 (channel-aggregated feature pyramid network, CA-FPN),针对目标尺度多样问题,设计并行多尺度空洞卷积块 (parallel multi-scale dilated convolution block, PDBlock) 替换 ResNet 块^[12]作为 AFPN 的基础模块,还引入通道聚合 (channel-aggregated, CA) 模块^[13]和通道注意力 (squeeze-and-excitation, SE) 模块^[14],增强模型对关键位置信息的捕获和保留能力,并利用残差连接实现跨分辨率信息传递,使网络兼顾全局结构理解和精细节恢复。

1 方法

1.1 CA-FPN 网络结构

CA-FPN 结构如图 1 所示,由 4 个阶段级联而成。

第 1 阶段,使用 3×3 卷积层预处理原始图像,首层卷积将通道数量从 3 增加到 16,后续各层卷积分辨率降至 1/4,通道尺寸增加 2 倍。预处理过程中各层特征图如图 2 所示,因层数越深图像损失信息越多,选第 4、5 和 6 层作为网络输入,通道尺寸及空间分辨率分别为 (128 层, 152 像素×152 像素)、(256 层, 76 像素×76 像素) 和 (512 层, 38 像素×38 像素)。

第 2 至 3 阶段,用 PDBlock 模块从每个阶段内不同分辨率分支提取特征,增加各分支深度;采用双向特征融合机制,低分辨率分支上采样后与高分辨率特征在通道维度拼接,高分辨率分支下采样后与低分辨率特征拼接,均采用自适应空间特征融合 (adaptively spatial feature fusion, ASFF) 模块^[15]融合。

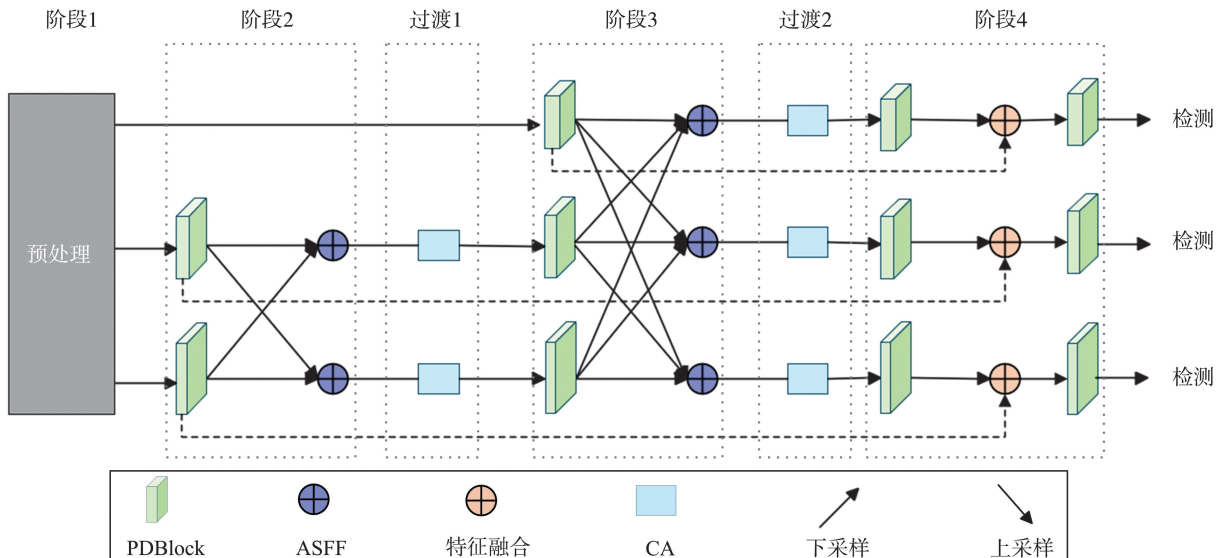


图 1 CA-FPN 网络结构
Fig.1 Structure of the CA-FPN network




图2 预处理模块各层特征图

Fig.2 Feature maps of each layer in the preprocessing module

在第2至3阶段后引入CA通道聚合模块减轻由上采样和下采样引起的信息损失,保留更多位置信息、提高模型准确性。

第4阶段,为最后3个特征图引入跨阶段残差连接,将预处理模块输出的原始多尺度特征分别与最终优化后的对应尺度特征进行残差连接。试验表明,加入原始多尺度特征检测效果增强。此设计既保留初始特征细粒度位置信息,又增强深层特征语义表达能力。

1.2 PDBlock

AFPN因堆叠许多ResNet块,存在有效感受野不足、单尺度卷积无法提取多尺度特征的问题。为改善有效感受野^[16],以不同的尺寸提取特征,本研究提出PDBlock基本模块。其核心是构建有差异化膨胀系数的并行卷积通路,如图3所示,其中 r 为维度变化比例。

该模块先设膨胀系数分别为1、2的分支通路,让单个模块可同时捕获 3×3 、 5×5 不同尺度的上下文信息;再引入SE通道注意力机制,用可学习权重系数对不同分支输出自适应加权,动态融合多尺度特征;模块内部采用残差连接,提升特征表达能力。

根据有效感受野理论^[17],模型有效感受野大小与 $K\sqrt{D}$ (K 为卷积核大小, D 为模型深度)成正比,增大卷积核更利于扩展感受野。为解决AFPN感受野局限,PDBlock引入 5×5 卷积块。通过可视化AFPN和CA-FPN的有效感受野,如图4所示,发现用较大卷积核的PDBlock显著扩大了感受野,能捕获更多视

觉信息,证实PDBlock对扩大感受野有效性。

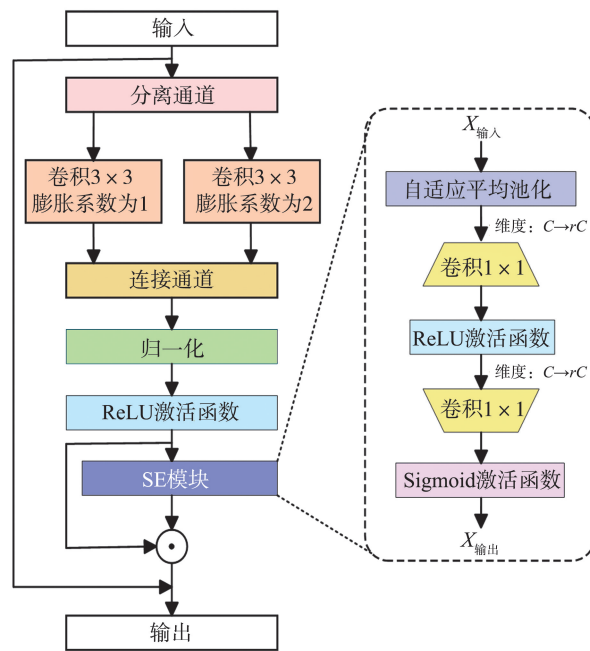



图3 PDBlock 结构

Fig.3 Structure of PDBlock



(a) AFPN

(b) CA-FPN

图4 AFPN和CA-FPN的感受野比较

Fig.4 Comparison of receptive fields between AFPN and CA-FPN

卷积神经网络中,卷积核大小决定有效感受野大小,用不同卷积核可在不同尺度提取特征,利于检测不同尺寸舰船目标。不同卷积核大小对感受野影响如图5所示。图5(a)显示原始图像,图5(b)证明较大卷积核适合提取较大舰船,但对于较小舰

船,较大卷积核的感受野会包含岸边、海浪等不必要信息^[18],不同尺寸感受野更适合不同尺寸舰船如图5(c)所示。因此,PDBlock采用不同卷积核组成的平行结构,提取更多多尺度特征,提高舰船检测的准确性。




图5 不同尺度感受野的比较

Fig.5 Comparison of receptive fields at different scales

用SSDD数据集对5个不同尺度卷积核进行试验比较,如图6所示。发现多尺度卷积核模型检测精度高于单尺度。当使用5×5和3×3卷积核时,模型达到最高检测精度。为最大程度减少较大卷积核引起的参数量增加,PDBlock引入空洞卷积,其膨胀系数定义内核中值间距,膨胀系数为2的3×3卷积核感受野与传统5×5卷积核相同,却只用9个参数,故PDBlock用其代替5×5卷积核。

船检测数据集(SAR ship detection dataset, SSDD)^[20]。LS-SSDD-v1.0数据集基于欧空局Sentinel-1卫星数据构建从星载SAR系统获取的15幅高分辨率影像切割为800像素×800像素的子图,共9000个样本用于网络训练与测试。SSDD包含1160幅SAR图像,标注2456个舰船目标实例,平均每图含2.12个检测目标,为算法性能评估提供多目标检测场景。试验硬件配置如表1所示。




图6 不同尺度的卷积核试验对比

Fig.6 Experimental comparison of convolutional kernels at different scales

2 试验设计

2.1 试验数据集

本试验采用两类SAR舰船检测数据集:大场景SAR舰船检测数据集(large-scale SAR ship detection dataset-v1.0, LS-SSDD-v1.0)^[19]和SAR舰

表1 环境配置

Table 1 Environment configuration

参数	配置
操作系统	Ubuntu22.04
GPU	Geforce RTX 4060 8 G
CPU	Intel(R)Core(TM) i5-12490F
内存	16 G
深度学习框架	Paddle2.6
Python版本	3.8
GPU加速平台	CUDA11.8

训练参数设置:用Adam优化器训练300个周期,输入图像分辨率800像素×800像素,批次大小为12,并行数据加载线程数为8,优化器初始学习率为0.01。

2.2 评价指标

在本试验中,所采用的检测精度评价指标为精确率、召回率和平均精度。精确度 P 和召回率 R 的计算公式为

$$P = \frac{P_T}{P_T + P_F}, \quad (1)$$

$$R = \frac{P_T}{P_T + N_F}, \quad (2)$$

式中: P_T 表示被模型正确识别为正类别的实例数目; N_F 表示实际属于正类别但被误分类为负类别的样本数量; P_F 表示实际属于负类别但被模型错误判定为正类别的样本数量。

平均精度 m_{AP} 作为目标检测任务的核心评价指标, 通过在预设 IoU 阈值(本研究采用 50%) 下, 综合计算不同目标尺寸与类别的平均检测精度 m_{AP50} , 其计算公式如下所示。

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

$$m_{AP} = \frac{1}{C} \sum_i^C P_{Ai}, \quad (4)$$

式中, $P(R)$ 为以召回率 R 为变量的准确率函数, P_{Ai} 为第 i 个类别的平均精度, C 为数据集中类别总数。从计算复杂度和部署需求两个维度继续完善评价体系: (1) 浮点运算量 G_{FLOPs} 表示单次推理所需十亿次浮点运算次数 (giga floating point operations per second, GFLOPs), 反映模型的计算效率; (2) 参数量 P_{params} 量化模型可训练参数的存储规模, 决定算法的部署可行性。

2.3 对比试验

为平衡模型精度与效率, 本研究探索预处理层通道配置优化空间。如表 2 所示, 通道数设为超轻量级 [64, 128, 256] 时, 模型 G_{FLOPs} 为 2.76、参数量为 1.01×10^6 , 但 m_{AP50} (0.965) 较峰值损失 0.8%; 扩张至 [256, 512, 1024], G_{FLOPs} 激增至 4.78, 精度降至 0.970。最终选 [128, 256, 512] 为基准配置, 以模型 G_{FLOPs} 为 3.19 和参数量为 1.17×10^6 达成 m_{AP50} 为 0.973 的最优平衡。

表 2 根据不同预处理层选择进行的通道对比试验

Table 2 Channel comparative experiments under different preprocessing layer selections

通道	P	R	m_{AP50}	G_{FLOPs}	$P_{Params}/10^6$
[64, 128, 256]	0.975	0.958	0.965	2.76	1.01
[72, 144, 288]	0.978	0.961	0.969	2.92	1.07
[128, 256, 512]	0.981	0.964	0.973	3.19	1.17
[256, 512, 1024]	0.979	0.962	0.970	4.78	1.75

基于优化通道配置, 在 SSDD 与 LS-SSDD 数据集开展对比试验。如表 3 所示, 在 SSDD 数据集中, CA-FPN 以 m_{AP50} 为 0.973 超越所有 SAR 检测模型, 精确度为 0.981 刷新纪录, 计算量仅需同等精度模型 MHASD 的 50.6% 算力, 参数量是 LPEDet 的 6.4%。如表 4 所示, 在 LS-SSDD 数据集中,

CA-FPN 以 m_{AP50} 为 0.736 与 YOLO-SARSO 基本持平, 召回率 0.672 领先, 计算量不足 YOLO-SARSO 的 40%, 参数量比 L-YOLO 降低 39.4%。试验证明 CA-FPN 在精度与轻量化上有双重突破, 为边缘端舰船检测提供新范式。

表 3 SSDD 数据集对比试验

Table 3 Comparative experiments on SSDD dataset

网络模型	P	R	m_{AP50}	G_{FLOPs}	$P_{Params}/10^6$
Picodet ^[21]	0.955	0.921	0.951	8.23	5.27
YOLOv10n ^[22]	0.931	0.965	0.961	8.20	2.70
YOLOv11n ^[23]	0.960	0.966	0.971	6.30	2.58
MobileNetV3 ^[24]	0.932	0.917	0.925	3.68	6.30
AFPN	0.897	0.949	0.945	4.24	1.93
LPEDet ^[25]	0.970	0.962	0.972	5.70	18.40
MHASD ^[26]	0.980	0.956	0.971	6.30	2.58
E-ShuffleV2 ^[27]	0.934	0.928	0.932	6.80	3.58
MSDFNet ^[28]	0.939	0.947	0.915	9.57	8.94
SFRT-DETR ^[29]	0.972	0.949	0.966	23.10	12.80
CA-FPN	0.981	0.964	0.973	3.19	1.17

表 4 LS-SSDD 数据集对比试验

Table 4 Comparative experiments on LS-SSDD dataset

网络模型	P	R	m_{AP50}	G_{FLOPs}	$P_{Params}/10^6$
Picodet	0.601	0.643	0.634	8.23	5.27
YOLOv10n	0.819	0.633	0.707	8.20	2.70
YOLOv11n	0.767	0.655	0.733	6.30	2.58
EfficientDet ^[30]	0.621	0.671	0.613	107.52	39.40
AFPN	0.701	0.642	0.701	4.24	1.93
YOLO-SARSI ^[31]	0.819	0.633	0.737	8.10	18.43
EDHC ^[32]	0.502	0.778	0.706	6.30	2.58
L-YOLO ^[33]	0.847	0.639	0.730	8.10	1.93
CA-FPN	0.833	0.672	0.736	3.19	1.17

2.4 可视化分析

CA-FPN 相较 YOLOv11n、AFPN 等先进算法的性能优势如图 7 所示, 其中绿色检测框表示正确检测结果, 红色标注框表示误检或漏检目标。简单目标场景中 (图 7 第 1 列) 各算法均能完整检测; 近岸目标 (图 7 第 2 列) 和密集目标检测 (图 7 第 3 列) 场景, CA-FPN 漏检率和误检率更低。

CA-FPN 算法有三大核心优势: 一是交叉注意力机制有效抑制近岸复杂背景干扰, 提升舰船轮廓特征提取能力; 二是动态特征融合策略增强对密集排列舰船的区分能力; 三是多尺度特征提取模块增强不同尺度舰船检测效果, 尤其小目标 (<50 像素) 检测。试验证实其能有效应对 SAR 图像斑点噪声等干扰, 为复杂海况舰船检测提供可靠技术方案。




图 7 CA-FPN 在 SSDD 测试集上的效果对比

Fig.7 Performance comparison of CA-FPN on SSDD test set

2.5 消融试验

为验证 CA-FPN 各模块有效性,在 SSDD 数据集进行消融试验,结果如表 5 所示。表中“√”表示以上模块被使用,“×”表示以上模块没被使用。以 AFPN 为基线,模型 1 用 PDBlock 替换 AFPN 的 ResNet 基础模块,得益于其大尺度感受野与多尺度特征提取能力, m_{AP50} 提升 1.1%;模型 2 在模型 1 基础上引入 SE 注意力机制,通过特征权重分配强化关键信息, m_{AP50} 进一步增加 0.6%;模型 3 在模型 2 中集成 CA 通道聚合模块,通过通道协同有效抑制冗余特征干扰,以极小的额外代价实现 m_{AP50} 提升 0.7%;模型 4 在模型 3 架构中嵌入跨层级残差连

接,通过语义信息交互增强特征融合效率,模型紧凑性显著改善, m_{AP50} 再提升 0.6%。试验数据表明,相较于原始 AFPN,本研究所提 CA-FPN 通过模块协同优化实现 2.8%的 m_{AP50} 性能跃升,参数量降低 39%,验证了轻量化设计与精度提升的双重可行性。

表 5 CA-FPN 的消融试验

Table 5 Ablation experiment of CA-FPN						
模型	AFPN	PDBlock	SE	CA	残差连接	m_{AP50}
AFPN	√	×	×	×	×	0.945
模型 1	√	√	×	×	×	0.954
模型 2	√	√	√	×	×	0.960
模型 3	√	√	√	√	×	0.967
模型 4	√	√	√	√	√	0.973

3 结论

SAR 舰船检测是遥感图像分析的重要研究方向,在海洋监测和海上搜救等领域意义重大。本研究针对复杂海况下的舰船检测需求,提出基于渐近式特征融合的轻量化检测网络 CA-FPN。通过构建 PDBlock 增强模型对多尺度目标的特征提取能力,结合 SE 注意力机制有效抑制了 SAR 图像斑点噪声的干扰。试验表明,相较传统检测算法,本研究所提模型在保持较高检测精度的同时,参数量减少 39%,在公开数据集 SSDD 上检测精度达 97.3%,验证了模型有效性。

然而,当前模型在极端恶劣海况下的虚警抑制能力仍有提升空间。未来将重点研究网络中的各层的重要性和功能,探索用更轻量级卷积替代现有标准卷积层,进一步压缩模型参数量。通过这些改进优化模型,使其更适用于参数和资源有限的环境,推动轻量化 SAR 舰船检测算法在资源受限平台的实际应用。

参考文献:

- [1] DONG G G, KUANG G Y, WANG N, et al. Classification via sparse representation of steerable wavelet frames on Grassmann manifold: application to target recognition in SAR image [J]. *IEEE Transactions on Image Processing*, 2017, 26(6): 2892-2904.
- [2] 张弘森, 徐建, 吴飞, 等. 基于深度学习的视觉图像舰船目标检测与识别方法综述 [J]. *指挥信息系统与技术*, 2024, 15(6): 48-63.
ZHANG Hongsen, XU Jian, WU Fei, et al. Review of ship target detection and recognition methods with visual imagery based on deep learning [J]. *Command Information System and Technology*, 2024, 15(6): 48-63.
- [3] 张尧, 张艳, 王涛, 等. 大场景 SAR 影像舰船目标检测的轻量化研究 [J]. *地球信息科学学报*, 2025, 27(1): 256-270.
ZHANG Yao, ZHANG Yan, WANG Tao, et al. Lightweight research on ship target detection in large-scale SAR images [J]. *Journal of Geo-Information Science*, 2025, 27(1): 256-270.
- [4] 张淑钟. SAR 图像舰船目标快速检测识别技术 [D]. 成都: 电子科技大学, 2022: 2-5.
ZHANG Lianzhong. Rapid detection and recognition technology of ship targets in SAR images [D]. Chengdu: University of Electronic Science and Technology of China, 2022: 2-5.
- [5] TANG X, ZHANG J F, XIA Y Z, et al. DBW-YOLO: a high-precision SAR ship detection method for complex environments [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2024, 17: 7029-7039.
- [6] CHEN S Q, ZHAN R H, WANG W, et al. Learning slimming SAR ship object detector through network pruning and knowledge distillation [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, 14: 1267-1282.
- [7] WANG Y T, MIAO M, ZHU S L. L-ENet: an ultra-lightweight SAR image detection network [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2024, 17: 8967-8978.
- [8] TAN X D, LENG X G, SUN Z Z, et al. Lightweight ship detection network for SAR range-compressed domain [J]. *Remote Sensing*, 2024, 16(17): 3284.
- [9] YU H, YANG S H, ZHOU S P, et al. VS-LSDet: a multiscale ship detector for spaceborne SAR images based on visual saliency and lightweight CNN [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2024, 17: 1137-1154.
- [10] 陈志文, 王坤, 周广蕴, 等. 基于胶囊网络及其权重剪枝的 SAR 图像变化检测方法 [J]. *计算机科学*, 2021, 48(7): 190-198.
CHEN Zhiwen, WANG Kun, ZHOU Guangyun, et al. SAR image change detection method based on capsule network with weight pruning [J]. *Computer Science*, 2021, 48(7): 190-198.
- [11] YANG G Y, LEI J, ZHU Z K, et al. AFPN: asymptotic feature pyramid network for object detection [C]//2023 IEEE International Conference on Systems, Man, and Cybernetics (SMC). Honolulu, USA: IEEE, 2023: 2184-2189.
- [12] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA: IEEE, 2016: 770-778.
- [13] LI S Y, WANG Z D, LIU Z C, et al. MogaNet: multi-order gated aggregation network [EB/OL]. (2025-06-16) [2025-06-25]. <https://arxiv.org/abs/2211.03295>
- [14] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA: IEEE, 2018: 7132-7141.
- [15] QIAO Y L, GUO Y Y, HE D J. Cattle body detection based on YOLOv5-ASFF for precision livestock farming [J]. *Computers and Electronics in Agriculture*, 2023, 204: 107579.

- [16] LIU Z, LIN Y T, CAO Y, et al. Swin transformer; hierarchical vision transformer using shifted windows [C]//2021 IEEE/CVF International Conference on Computer Vision. Montreal, Canada: IEEE, 2021; 10012-10022.
- [17] LUO W, LI Y, URTASUN R, et al. Understanding the effective receptive field in deep convolutional neural networks [C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach, USA: Curran Associates Inc., 2017; 4905-4914.
- [18] VASWANI A, RAMACHANDRAN P, SRINIVAS A, et al. Scaling local self-attention for parameter efficient visual backbones [C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, USA: IEEE, 2021; 12889-12899.
- [19] ZHANG T W, ZHANG X L, KE X, et al. LS-SSDD-v1.0: a deep learning dataset dedicated to small ship detection from large-scale sentinel-1 SAR images [J]. Remote Sensing, 2020, 12(18): 2997.
- [20] ZHANG T W, ZHANG X L, LI J W, et al. SAR ship detection dataset (SSDD): official release and comprehensive data analysis [J]. Remote Sensing, 2021, 13(18): 3690.
- [21] YU G H, CHANG Q Y, LV W Y, et al. PP-PicoDet: a better real-time object detector on mobile devices [EB/OL]. (2021-11-01) [2025-06-25]. <https://arxiv.org/abs/2111.00902>
- [22] WANG A, CHEN H, LIU L, et al. Yolov10: real-time end-to-end object detection [EB/OL]. (2024-10-30) [2025-06-25]. <https://arxiv.org/abs/2405.14458>
- [23] KHANAM R, HUSSAIN M. YOIOv11: an overview of the key architectural enhancements [EB/OL]. (2024-10-23) [2025-06-25]. <https://www.arxiv.org/abs/2410.17725>
- [24] HOWARD A, SANDLER M, CHEN B, et al. Searching for MobileNetV3 [C]//2019 IEEE/CVF International Conference on Computer Vision. Seoul: IEEE, 2019; 1314-1324.
- [25] FENG Y, CHEN J, HUANG Z X, et al. A lightweight position-enhanced anchor-free algorithm for SAR ship detection [J]. Remote Sensing, 2022, 14(8): 1908.
- [26] YU N J, REN H H, DENG T M, et al. A lightweight radar ship detection framework with hybrid attentions [J]. Remote Sensing, 2023, 15(11): 2743.
- [27] 唐志勇, 魏雪云, 江蒋伟, 等. 基于 YOLO 框架的轻量化 SAR 图像舰船检测方法研究 [J]. 无线电工程, 2024, 54(10): 2347-2354.
- TANG Zhiyong, WEI Xueyun, JIANG Jiangwei, et al. Research on lightweight SAR image ship detection method based on YOLO framework [J]. Radio Engineering, 2024, 54(10): 2347-2354.
- [28] SUN Z Z, LENG X G, ZHANG X H, et al. Arbitrary-direction SAR ship detection method for multiscale imbalance [J]. IEEE Transactions on Geoscience and Remote Sensing, 2025, 63: 5208921.
- [29] CAO J, HAN P H, LIANG H P, et al. SFRT-DETR: a SAR ship detection algorithm based on feature selection and multi-scale feature focus [J]. Signal, Image and Video Processing, 2024, 19(2): 115.
- [30] TAN M X, PANG R M, LE Q V. Efficientdet: scalable and efficient object detection [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE, 2020; 10778-10787.
- [31] TANG H D, GAO S, LI S, et al. A lightweight SAR image ship detection method based on improved convolution and YOLOv7 [J]. Remote Sensing, 2024, 16(3): 486.
- [32] LIU Y B, YAN G, MA F, et al. SAR ship detection based on explainable evidence learning under intraclass imbalance [J]. IEEE Transactions on Geoscience and Remote Sensing, 2024, 62: 5207715.
- [33] XU X W, ZHANG X L, ZHANG T W, et al. On-board ship detection in SAR images based on L-YOLO [C]//2022 IEEE Radar Conference (RadarConf22). New York, USA: IEEE, 2022; 1-5.

(编辑:管昕昉)