基于深度学习的SAR图像定向船舶检测算法

李亚森

上海理工大学光电信息与计算机工程学院,上海

收稿日期: 2025年4月26日; 录用日期: 2025年5月19日; 发布日期: 2025年5月27日

摘要

合成孔径雷达(SAR)图像船舶目标检测在民用和军事领域发挥着越来越重要的作用。然而,SAR图像中的船舶具有密集排列、任意方向和多尺度等特点。针对这些问题,文章提出了一种改进YOLOv11的SAR图像定向船舶检测方法YOLOv11-FM。首先,设计了一种快速混合聚合网络FMANet,增强网络的特征学习和提取能力。其次,提出了一种双向自适应特征融合网络BAFFN,通过跨层连接的方式实现更丰富的特征交互与融合。最后,采用小波特征增强模块WFU,改进颈部网络中上采样融合模块,增强船舶的细节信息。实验结果表明,YOLOv11-FM在RSDD-SAR船舶目标检测数据集上的P和AP50分别达到了94%和97.6%,具有良好的检测效果。

关键词

目标检测,定向船舶检测,合成孔径雷达,YOLOv11,特征融合

Oriented Ship Detection Algorithm for SAR Images Based on Deep Learning

Yasen Li

School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai

Received: Apr. 26th, 2025; accepted: May 19th, 2025; published: May 27th, 2025

Abstract

Synthetic Aperture Radar (SAR) imagery for ship target detection plays an increasingly important role in civil and military applications. However, ships in SAR images are characterized by dense arrangement, arbitrary orientation, and multi-scale. To address these issues, this paper proposes a directional ship detection method, YOLOv11-FM, for SAR images with improved YOLOv11. Firstly, a fast hybrid aggregation network, FMANet, is designed to enhance the feature learning and extraction capability of the network. Secondly, a bidirectional adaptive feature fusion network BAFFN is

proposed to realize richer feature interaction and fusion through cross-layer connection. Finally, the wavelet feature enhancement module WFU is used to improve the up-sampling fusion module in the neck network and enhance the ship's detailed information. The experimental results show that YOLOv11-FM has a good P and AP₅₀ of 94% and 97.6%, respectively, on the RSDD-SAR ship target detection dataset.

Keywords

Target Detection, Oriented Ship Detection, Synthetic Aperture Radar, YOLOv11, Feature Fusion

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0). http://creativecommons.org/licenses/by/4.0/

CC ① Open Access

1. 引言

合成孔径雷达(Synthetic Aperture Radar,简称 SAR)是一种高分辨率成像雷达系统,比光学遥感系统 具有更明显的优势,能够在各种天气条件和光照条件下工作[1]。近年来,已经出现了许多关于 SAR 图像 目标检测的研究成果,重点包括检测飞机、船舶和车辆等目标[2]。其中,船舶检测对于渔业管理、港口 管制和海洋监测等方面提供了很大帮助[3]。但是,船舶通常稀疏地分布在公海,密集地挤在海岸附近, 这使得对 SAR 图像船舶检测充满了挑战。

在 SAR 图像检测领域,算法最初应用了基于水平边界框(HBB)的方法进行船舶检测。例如, Chen 等 人[4]提出了 CSD-Yolo 算法,通过结合置换注意力机制和空洞空间金字塔池化,以增强该模型的多尺度 特征提取能力。Li 等人[5]提出一个注意力引导的平衡特征金字塔网络,减小背景杂波和噪声对船舶检测 的影响,从而增强了对多尺度船舶的检测性能。Zhu 等人[6]提出了一个名为 DB-YOLO 的 SAR 船舶检测 器,通过改进跨阶段的子模块来增强信息融合,实现对小目标的准确检测。Zhou 等人[7]提出了一种分步 特征细化主干和金字塔网络,通过分步空间信息解耦函数依次细化船舶的位置和轮廓,提高船舶检测性能。

上述方法主要采用水平边界框进行船舶检测。但是,船舶通常具有较大的纵横比,这使得难以使用 HBB准确直观地传达出它们的方向和尺寸信息。并且在港口等船舶密集分布的区域,HBB可能与主要目 标周围的其他船舶目标重叠,导致检测精度降低。相反,基于定向边界框(OBB)的检测器可以为船舶目标 提供更精确的定位和方向信息,并且更适合于 SAR 图像中的船舶检测。Sun 等人[8]提出一种具有双向特 征融合架构的任意方向边界框检测模型,并将角度信息作为一个整体进行分类,生成符合船舶目标方向 的边界框。Zheng 等人[9]提出一种用于 SAR 图像中旋转船舶检测的方法,引入了旋转角度的概念,使其 适用于旋转框检测场景。Wang 等人[10]提出了一种两阶段网络,通过结合多尺度上下文语义信息融合模 块和散射点信息学习模块,以增强检测的鲁棒性。

综上所述,目前 SAR 图像在船舶检测领域已经取得了较多研究成果。然而,在实际应用中仍存在许 多挑战。例如,对于近岸船舶检测,由于场景庞大复杂、船舶分布密集且具有任意方向性,从而增加了 将船舶目标与近岸港口和建筑物分开的困难。对于小目标,通常由于占据图像中较小区域并且缺乏明确 的细节信息而难以检测到它们。此外,不同图像中船舶目标尺寸存在多尺度差异,这进一步增加了检测 的难度。因此,针对上述提到的这些挑战,本文在 YOLOv11 框架[11]的基础上进行改进,提出了一种 SAR 图像定向船舶检测方法 YOLOv11-FM,旨在增强对复杂环境中多尺度船舶目标的检测性能。主要创新如下:

1) 设计了一种快速混合聚合网络(Fast Mixed Aggregation Network, FMANet), 增强主干网络的特征提

取能力。

2) 提出了一种双向自适应特征融合网络(Bi-Directional Adaptive Feature Fusion Network, BAFFN),通过跨层连接的方式实现更丰富的特征交互与融合。

3) 采用小波特征增强(Wavelet Feature Upgrade, WFU)模块[12]改进颈部网络中上采样融合模块,避免高低频信息的混叠。

2. 算法框架

2.1. YOLOv11-FM 模型结构

本文以 YOLOv11 模型为基础,在主干网络、特征融合网络和颈部上采样融合模块三个方面进行了 改进,其结构如图 1 所示。首先,在模型的主干网络中加入本文提出的 FMANet 模块,以增强对目标特 征的提取能力。接着,通过双向自适应特征融合网络实现跨尺度特征融合与交互,并在自下而上的路径 中采用 WFU 模块,从而有效整合不同层级的语义和空间信息。最后,通过检测头执行分类和回归任务。



Figure 1. YOLOv11-FM model structure diagram 图 1. YOLOv11-FM 模型结构

2.2. 快速混合聚合网络

合成孔径雷达(SAR)图像中的船舶分布并不规则。尤其是在近岸环境中,船舶往往密集排列,呈现出

的特征信息不够鲜明、轮廓相对模糊,并且易受邻近海岸建筑物的干扰,从而导致漏检或定位不准确。因此,在 SAR 图像中高效提取船舶特征成为一个颇具挑战性的难题。针对此问题,本文基于混合聚合网络(MANet) [13]和 FasterNet 模块[14],提出了快速混合聚合网络(FMANet),如图 2 所示。通过增强船舶目标在复杂环境中的特征表达能力,使网络能够更好地捕捉图像中的语义信息。



Figure 2. Structural diagram of fast mixed aggregation network 图 2. 快速混合聚合网络结构图

FMANet 结合了三种类型的模块来丰富信息流,从而增强主干网络的特征提取能力。其中,1×1旁 路卷积用于通道特征重新校准,通过调整通道间的特征权重来增强重要特征,抑制不重要特征。用于高 效空间特征处理的深度可分离卷积(DSConv)将标准卷积分解为深度卷积和逐点卷积。深度卷积对每个输 入通道分别进行空间卷积,然后逐点卷积再对深度卷积的输出进行通道间的线性组合。这种设计能够有 效地提取图像的空间特征(如边缘、纹理等),同时提高计算效率。C2f 模块通过提取多层次的特征,能够 增强特征表达能力。这种融合在训练阶段产生了更加丰富的梯度流,有助于网络更好地学习特征,显著 增强了每个阶段基本特征所包含的语义深度。FMANet 用公式表示如下:

$$\begin{cases} X_{mid} = Conv_1(X_{in}) \\ X_1 = Conv_2(X_{mid}) \\ X_2 = DSConv(Conv_3(X_{mid})) \\ X_3, X_4 = Split(X_{mid}) \\ X_5 = PConvNeck_1(X_4) + X_4 \\ X_6 = PConvNeck_2(X_5) + X_5 \\ \dots \\ X_{4+n} = PConvNeck_n(X_{3+n}) + X_{3+n} \end{cases}$$
(1)

其中, X_{mid} 的通道数为 2c, 而 $X_1, X_2 \cdots X_{4+n}$ 的通道数均为 c。最后, 再通过拼接操作融合三种类型特征 的语义信息,并利用 1×1 卷积进行通道压缩, 最终生成通道数为 2c 的 X_{out} , 公式描述如下:

$$X_{out} = Conv_0 \left(X_1 \| X_2 \| \| \cdots \| X_{4+n} \right)$$

$$\tag{2}$$

FasterNet 模块包含一个部分卷积(PConv)层[14],后接两个逐点卷积(PWConv)层。如图 3 所示,部分 卷积只对输入通道的一部分应用常规卷积进行空间特征提取,其余通道保持不变。通过同时减少冗余计 算和内存访问,更有效地提取空间特征。为了充分且高效地利用所有通道的信息,在部分卷积的基础上 进一步添加了一个逐点卷积。它们在输入特征图上的有效感受野看起来像一个 T 形卷积,与均匀处理一 个局部区域的常规卷积相比,这种设计更加关注局部区域中包含最丰富的信息中心位置,提高了特征提 取的效率和效果。



Figure 3. Structural diagram of partial convolution 图 3. 部分卷积结构图

2.3. 双向自适应特征融合网络



Figure 4. Structural diagram of bi-directional adaptive feature fusion network 图 4. 双向自适应特征融合网络结构图

将 SAR 图像输入主干网络后,可以获得不同层次的特征图。较浅层的特征图包含丰富的空间信息和局部特征。而较深层的特征图包含丰富的语义信息,但空间细节丢失较多。因此深层特征图无法提供精确定位船舶目标所需的空间信息,且随着特征图分辨率降低,小尺度目标的特征会逐渐丢失,这将严重影响 SAR 船舶检测的最终效果。针对该问题,本文提出了一种基于自适应融合(Adaptive Fusion, AF)模块[15]的双向自适应特征融合网络(BAFFN),其结构如图 4 所示。通过跨层连接的方式实现更高级别的特征融合,增强它们之间的信息交互,从而提高模型对多尺度船舶的检测性能。

自适应融合的核心思想是动态地为每个输入特征分配权重,然后根据这些权重对特征进行加权求和,得到一个融合后的特征。具体来说,假设输入的大小可以表示为(bs, C, H, W),然后通过卷积、拼接和 Softmax 操作获得一个空间自适应权重,其大小为(bs, 3, H, W)。这三个通道与三个输入一一对应,再通 过计算加权和,可以将上下文信息聚合到输出中。

2.4. 小波特征增强模块

在颈部网络中,直接采用上采样将不同分辨率的特征对齐,再进行融合可能会导致高低频信息的混 叠,从而影响目标检测的性能。因此,本文引入了小波特征增强(WFU)模块[12],如图 5 所示。WFU 模 块通过小波变换 WT 将特征图分解为高频和低频分量,分别进行处理后再融合,这样可以更好地增强船 舶的细节信息和整体轮廓。具体来说,对于较大尺寸 $F_s \in R^{\frac{H}{4} \times \frac{W}{4} \times 4C}$ 和较小尺寸 $F_{s+1} \in R^{\frac{H}{8} \times \frac{W}{8} \times 4C}$,首先对较 大尺寸 F_s 应用小波变换,得到与 F_{s+1} 相同尺寸的四个小波子带:

$$WT(F_s) = \left\{ A_{LL}^s, H_{LR}^s, V_{RL}^s, D_{RR}^s \right\}$$
(3)

其中, A_{LL}^{s} 表示 F_{s} 的低频部分, H_{LR}^{s} 、 V_{RL}^{s} 和 D_{RR}^{s} 表示 F_{s} 的三个高频部分。由于小尺度特征 F_{s+1} 主要包含低频信息, 所以将 A_{LL}^{s} 与它组合作为增强后的低频子带。同时, 使用残差块来增强图像的高频分量。最终,通过逆小波变换 *IWT* 得到输出 $F_{s}^{r} \in R^{\frac{H}{4} \times \frac{W}{4} \times 4C}$:

$$F_{S} = IWT\left(C\left(A_{LL}^{S}, F_{S+1}\right), R\left(H_{LR}^{S}, V_{RL}^{S}, D_{RR}^{S}\right)\right)$$

$$\tag{4}$$

其中, IWT 表示逆小波变换, C 表示拼接, R 表示标准残差块。



Figure 5. Structural diagram of wavelet feature upgrade 图 5. 小波特征增强模块结构图

3. 实验环境与数据集

3.1. 实验环境与参数

实验采用 PyTorch 2.1.2 开源深度学习框架搭建网络, GPU 采用 NVIDIA RTX 3090 (24 G)。并使用

SGD 优化器进行训练,初始学习率为0.01,动量为0.937,训练迭代次数为300次,批量大小为32。

3.2. 数据集

为了评估模型的性能,本文使用公开的 SAR 图像船舶检测数据集 RSDD-SAR [16]作为实验数据集。 RSDD-SAR 数据集包含 7000 张分辨率为 512×512 的图像,其中共有 10,263 艘船只。该数据集还涵盖了 各种场景,包括港口、航运通道和岛屿等。训练集、验证集和测试集按照 7:1:2 的比例随机划分。

3.3. 评估指标

为了更好地评估所提出方法的性能,我们采用精确率(P)、召回率(R)和平均精度(Average Precision, AP) 作为评估指标。

$$P = \frac{TP}{TP + FP} \tag{5}$$

$$R = \frac{TP}{TP + FN} \tag{6}$$

$$AP = \int_0^1 P(R) dR \tag{7}$$

其中, TP 是正确预测的正样本, FP 是错误预测的正样本, FN 是错误预测的负样本, P(R)为准确率 - 召回率曲线。

根据不同的 IoU 阈值,平均精度可以分为 AP₅₀和 AP_{50:95}。当 IoU 阈值设置为 0.5 时,式(7)计算得到的结果即 AP₅₀。如果 IoU 在 0.5 和 0.95 之间以 0.05 的步长逐渐增加,则获得的十个值的平均值为 AP_{50:95}。

4. 实验结果分析

4.1. 消融实验

为验证各项改进模块的有效性,我们在 RSDD-SAR 数据集上进行了消融实验。由表 1 实验结果可见,各项改进措施均带来了精度和召回率的提升。YOLOv11-FM 与 YOLOv11 模型相比,AP₅₀和 AP₅₀₉₅分别提高了 0.5%和 0.9%。因此,所提出的这些改进模块是有效的,增强了网络检测船舶目标的性能。

 Table 1. Impact of different improvement sections on detection performance

 表 1. 不同改进部分对检测性能的影响

算法	FMANet	BAFFN	WFU	Р	R	AP50	AP50:95
YOLOv11				0.933	0.928	0.971	0.743
(a)	\checkmark			0.937	0.934	0.973	0.747
(b)		\checkmark		0.938	0.933	0.975	0.750
(c)			\checkmark	0.935	0.931	0.972	0.745
YOLOv11-FM	\checkmark	\checkmark	\checkmark	0.940	0.936	0.976	0.752

4.2. 对比实验

为全面评估 YOLOv11-FM 在 SAR 图像船舶检测任务中的性能,将其与其他一些经典目标检测算法进行对比。表 2 给出了 YOLOv11-FM 与其他目标检测算法在 RSDD-SAR 数据集上的检测结果[17]。可以看出,相较于其他目标检测算法,YOLOv11-FM 的准确率提高了 3%~21.4%,召回率提高了 2%~21.3%,

AP₅₀提高了 9.2%~30.9%。这些结果表明我们提出的 YOLOv11-FM 在精度、召回率和 AP₅₀均优于其他模型,同时还保持了相对适中的参数量。

算法	Р	R	AP50	Params (M)
R-Faster R-CNN	0.850	0.877	0.833	41.41
R-RetinaNet	0.726	0.723	0.667	32.44
R3Det	0.865	0.884	0.809	41.81
S2ANet	0.910	0.916	0.879	36.45
ReDet	0.901	0.902	0.884	31.57
YOLOv11-FM	0.940	0.936	0.976	38.81

Table 2. Comparison of YOLOv11-FM model with other models 表 2. YOLOv11-FM 模型与其他模型对比

4.3. 检测结果可视化

为直观验证本文模型的检测效果,将 YOLOv11-FM 在 RSDD-SAR 数据集中部分图像的检测结果可 视化,如图 6 所示。第一行图片中的绿色框表示船舶的真实框,第二行图片中的红色框表示本文模型对 图像中船舶的检测框。可以看出,YOLOv11-FM 能够准确地检测到任意方向的船舶目标,表现出了巨大 潜力。



Figure 6. Detection effect diagram of YOLOv11-FM 图 6. YOLOv11-FM 检测效果图

5. 结束语

针对 SAR 图像船舶目标检测出现漏检和误检的问题,本文提出了一种改进 YOLOv11 的定向船舶检测方法 YOLOv11-FM。其中,FMANet 通过增强船舶目标的特征表达,提高了网络的特征学习和提取能力。BAFFN 通过跨层连接的方式实现更高级别的特征融合,有助于检测多尺度船舶目标。WFU 模块能够增强船舶的特征细节信息,提升模型的检测精度。实验结果表明,YOLOv11-FM 优于其他目标检测算

法,能够应对复杂环境条件下对多尺度船舶目标的检测任务。

参考文献

- [1] 郭倩, 王海鹏, 徐丰. SAR 图像飞机目标检测识别进展[J]. 雷达学报, 2020, 9(3): 497-513.
- [2] 邓云凯, 禹卫东, 张衡, 等. 未来星载 SAR 技术发展趋势[J]. 雷达学报, 2020, 9(1): 1-33.
- [3] Zhang, J., Zhang, X., Fan, C. and Meng, J. (2016) Discussion on Application of Polarimetric Synthetic Aperture Radar in Marine Surveillance. *Journal of Radars*, **5**, 596-606.
- [4] Chen, Z., Liu, C., Filaretov, V. and Yukhimets, D. (2023) Multi-Scale Ship Detection Algorithm Based on YOLOV7 for Complex Scene SAR Images. *Remote Sensing*, 15, Article 2071. <u>https://doi.org/10.3390/rs15082071</u>
- [5] Li, X., Li, D., Liu, H., Wan, J., Chen, Z. and Liu, Q. (2022) A-BFPN: An Attention-Guided Balanced Feature Pyramid Network for SAR Ship Detection. *Remote Sensing*, 14, Article 3829. <u>https://doi.org/10.3390/rs14153829</u>
- [6] Zhu, H., Xie, Y., Huang, H., Jing, C., Rong, Y. and Wang, C. (2021) DB-YOLO: A Duplicate Bilateral YOLO Network for Multi-Scale Ship Detection in SAR Images. *Sensors*, 21, Article 8146. <u>https://doi.org/10.3390/s21238146</u>
- [7] Zhou, Y., Wang, S., Ren, H., Hu, J., Zou, L. and Wang, X. (2024) Multi-Level Feature-Refinement Anchor-Free Framework with Consistent Label-Assignment Mechanism for Ship Detection in SAR Imagery. *Remote Sensing*, 16, Article 975. <u>https://doi.org/10.3390/rs16060975</u>
- [8] Sun, Z., Leng, X., Lei, Y., Xiong, B., Ji, K. and Kuang, G. (2021) BiFA-YOLO: A Novel Yolo-Based Method for Arbitrary-Oriented Ship Detection in High-Resolution SAR Images. *Remote Sensing*, 13, Article 4209. <u>https://doi.org/10.3390/rs13214209</u>
- [9] Ziyang, Z., Ting, Z., Zhaoying, L., Yujian, L. and Changming, S. (2022) A SAR Image Ship Detection Method Based on Rotated Loss Function RCIOU. *Journal of Shandong University (Natural Science)*, 52, 15-22.
- [10] Wang, H., Liu, S., Lv, Y. and Li, S. (2023) Scattering Information Fusion Network for Oriented Ship Detection in SAR Images. *IEEE Geoscience and Remote Sensing Letters*, 20, 1-5. <u>https://doi.org/10.1109/lgrs.2023.3324933</u>
- [11] Jocher, G. and Qiu, J. (2024) Ultralytics YOLO11. https://github.com/ultralytics/ultralytics
- [12] Li, W., Guo, H., Liu, X., Liang, K., Hu, J., Ma, Z., et al. (2024) Efficient Face Super-Resolution via Wavelet-Based Feature Enhancement Network. Proceedings of the 32nd ACM International Conference on Multimedia, Melbourne, 28 October 2024-1 November 2024, 4515-4523. <u>https://doi.org/10.1145/3664647.3681088</u>
- [13] Feng, Y., Huang, J., Du, S., et al. (2024) Hyper-YOLO: When Visual Object Detection Meets Hypergraph Computation. arxiv:2408.04804.
- [14] Chen, J., Kao, S., He, H., Zhuo, W., Wen, S., Lee, C., et al. (2023) Run, Don't Walk: Chasing Higher FLOPS for Faster Neural Networks. 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Vancouver, 17-24 June 2023, 12021-12031. <u>https://doi.org/10.1109/cvpr52729.2023.01157</u>
- [15] Xiao, J., Zhao, T., Yao, Y., et al. (2022) Context Augmentation and Feature Refinement Network for Tiny Object Detection. Proceedings of the International Conference on Learning Representations, 25-29 April 2022, Online, 1-11.
- [16] Xu, C., Su, H., Li, J., Liu, Y., Yao, L., Gao, L., Yan, W. and Wang, T. (2022) RSDD-SAR: Rotated Ship Detection Dataset in SAR Images. *Journal of Radars*, 11, 581-599.
- [17] Wan, H., Chen, J., Huang, Z., Du, W., Xu, F., Wang, F., et al. (2023) Orientation Detector for Ship Targets in SAR Images Based on Semantic Flow Feature Alignment and Gaussian Label Matching. *IEEE Transactions on Geoscience* and Remote Sensing, 61, 1-16. <u>https://doi.org/10.1109/tgrs.2023.3323143</u>