DOI: 10.13382/j.jemi.B2205545

基于 YOLOv5 的多分支注意力 SAR 图像舰船检测*

胡 欣 马丽军
(长安大学电子控制与工程学院 西安 710000)

摘 要:针对合成孔径雷达图像噪声大,成像特征不明显,尤其在面对海陆边界、港口码头、近岸岩礁等复杂场景,通常的检测算法对 SAR 图像目标特征提取困难,导致检测精度不高,出现误检漏检等问题。在 YOLOv5 的基础上设计了一种旋转的目标检测方法,提出了多分支注意力模块可以跨维度的信息融合,能更好地提取 SAR 图像目标中的位置信息和语义信息,以提高检测精度。此外,由于旋转目标检测会产生边界不连续问题影响边界框的回归,因此,利用了圆形平滑标签的方法将角度参数从回归问题转为分类问题,由此提高了精度。最后在 HRSID、SSDD+数据集上进行了实验,精度分别达到 84.98%和 90.13%,比原始的 YOLOv5 算法分别提升了 1.29%和 2.57%,实验结果证明所提算法的有效性。

关键词: 合成孔径雷达;旋转目标检测;多分支注意力;圆形光滑标签
中图分类号: TN957.52 文献标识码: A **国家标准学科分类代码**: 510.40

Multi-branch attention SAR image ship detection based on YOLOv5

Hu Xin Ma Lijun
(School of Electronics and Control Engineering, Chang′an University, Xi′an 710000, China)

Abstract: In view of the high noise of synthetic aperture radar images and inconspicuous imaging features, especially in complex scenes such as sea and land boundaries, ports, and coastal reefs, it is difficult for common detection algorithms to extract target features from SAR images, resulting in low detection accuracy and leak detection, etc. This paper designs a rotating target detection method based on YOLOv5, and proposes that the multi-branch attention module can be used for cross-dimensional information fusion, which can better extract the location information and semantic information in SAR image targets. In addition, the boundary discontinuity will be caused by rotating target detection, which will affect the regression of the bounding box. Therefore, the circular smooth label method is used to transform the angle parameter from regression problem to classification problem, thus improving the accuracy. Finally, experiments are carried out on HRSID and SSDD+ datasets, and the accuracy reaches 84.98% and 90.13%, respectively, which is 1.29% and 2.57% higher than the original YOLOv5 algorithm, respectively. Experimental results prove the effectiveness of the proposed algorithm.

Keywords: synthetic aperture radar; rotated object detection; multi-branch attention; circular smooth label

0 引 言

合成孔径雷达(synthetic aperture radar,SAR),是一种主动式的微波遥感系统,具有全天候、全天时、不受自然因素影响的优点,目前已经成为人们对地观测的重要手段之一。近年来,随着 SAR 图像的海量增长,利用 SAR 数据进行目标检测已成为重要的研究方向之一。高分辨率的 SAR 系统的分辨率已经可以达到厘米级,在军事方面,能够清晰的对海面舰船,陆地坦克,装甲车等进行成像,在民用领域,可以对海面渔船,漂浮物进行检测[1]。

传统的 SAR 图像目标检测算法主要有基于背景杂波统计分布的恒虚警率(constant false alarm rate,CFAR)[2]检测算法和人工提取纹理特征的检测算法。绝大多数 CFAR 算法基于局部滑窗对 SAR 图像进行逐像

收稿日期: 2022-05-30 Received Date: 2022-05-30
*基金项目:国家重点研发计划(2020YFB1600400)、科技部国家重点研发计划(2021YFB1600202)项目资助

素检测,SAR 图像中的每一个像素多次参与了滑窗运算,致使算法计算速度普遍不高。而人工提取图像纹理特征的算法需要人工提取设计,整个过程复杂耗时,难以保证检测的时效。

近年来,基于卷积神经网络(convolutional neural networks, CNN)的目标检测算法迅速发展,并且取得了优异的检测性能。目标检测算法大致可以分二阶段检测和一阶段检测两类,二阶段检测器首先是提取预图像中的感兴趣区域,然后利用这些区域的特征预测对象类别并且回归边界框。如 R-CNN[3]、Fast R-CNN[4]、Faster R-CNN[5]。虽然二阶段的方法在精度方面表现出了优异的结果,但是一阶段检测器简化了整个过程,将其视为一个回归问题并且实现了更高的速度。YOLO[6-9]系列、SSD[10]、RetinaNet[11]是最具代表性的单阶段检测方法。有很多研究者在此基础上进行改进,提出了不同场景的改进算法。史朋飞等[12]提出了一种结合数据增强的 YOLOv4 水下目标检测算法,通过在主干网络中添加注意力模块提高网络特征提取能力,使用数据增强提升网络模型的鲁棒性;Guo 等[13]在 CenterNet 基础上,提出了 CenterNet++算法,设计了特征细化模块、特征金字塔融合模块和头部增强模块,得到了不错的检测效果;吕禾丰等[14]提出了一种改进的 YOLOv5 的交通标志检测算法,首先改进了损失函数,提高了算法的精度,其次改进了 NMS 后处理算法,提高了检测框的准确率;Zhang 等[15]提出了 Quad-FPN,由 4 个独特的 FPN 组成,结果表明了在海洋监测的实用价值。虽然以上的研究都取得了一定的进展,但是在面对复杂场景时,任然有漏检误检等问题,而且没有引入旋转检测方法,在面对具有角度倾向和密集排列目标时影响检测效果。

随着星载 SAR 成像平台的快速发展,出现了越来越多的高质量 SAR 数据集。但是大多数 SAR 数据集中,包含远海和近岸两种类型的图像,这两类图像差异性大,近岸图像往往包含人造的虚警目标,给检测带来非常大的挑战。因此,本文设计注意力模块 MBAM,能够将目标特征细化,更好地分辨出虚警目标和真实目标。

旋转目标检测与常规的检测相比,在特定的应用场景更具有优势,水平框虽然涉及的参数较少,可以简化模型的训练过程,但是物体的检测框通常会包含许多背景区域,不仅会增加分类的难度,而且也会导致目标表示范围不准确等问题。而旋转检测可以有效解决上述问题,首先,旋转框在检测物体的时候基本不会发生重叠的问题,其次旋转框可以更精确的定位图像中的物体,并且检测框中几乎不含背景,可以减少背景对分类物体的影响。航空图像和文本图像检测中最先运用了旋转检测的方法,SAR 图像也具有相似特点,因此,将旋转检测引入 SAR 图像检测也是一项重要的工作。

本文的贡献主要有如下几个方面:

1)设计了一种基于注意力机制的旋转目标检测算法,算法核心是针对 CNN(convolutional neural network)对 SAR 图像提取的特征不够精细,导致在面对具有海岸这种复杂图像时会产生误检,漏检等情况;引入旋转检测算法,减少检测物体的重叠,使检测框更精确的定位物体。

2)提出了注意力模块 MBAM,分别在不同的 3 个维度对提取特征进行跨维度的信息融合,通过注意力结构可以将提取特征细化,网络对于具有目标的空间特征和通道特征会有更高的注意力表示。在面对小目标检测精度不佳的问题,本文修改 FPN(feature pyramid networks),将这种新颖的注意力模块分别在 FPN 的前向网络中,之后再与前一层的特征图进行拼接,以此将深层次的网络信息与浅层次的信息在不同维度间进行融合,实验证明,这种结构具有非常好的效果。

3)利用基于圆形平滑标签(circular smooth label, CSL)的旋转框检测方法实现精准定位,将角度预测转化为一个高精度分类任务,解决了边界不连续问题,也更有利于对密集排列目标的检测。

1　网络结构

YOLO 系列是非常优异的单阶段目标检测器,不仅具有非常好的检测精度,而且检测速度相对其他检测器具有非常大的优势,因此,本文以 YOLOv5 为检测的基本结构。

1.1　改进的网络结构

改进的网络结构如图 1 所示,首先将输入的 SAR 图像自适应的缩放,然后通过主干网络 CSPDarknet 提取特征,选取最后 3 层特征 P3、P4、P5 进行特征融合,由于顶层的特征是相对抽象的语义特征,对于 SAR 图像而言,会丢失浅层的位置信息,所以本文中 P3、P4、P5 特征层经过 MBAM 对特征进行全维度的融合,将底层的语义信息在不同维度进行交互,然后与前一层拼接,可以有效的将深层信息和浅层信息结合起来,最后将再将 3 个不同尺度的特征图进行预测,经过非极大抑制处理(non-maximum suppression,NMS)处理,得到检测结果。

1.2　多分支注意力模块(MBAM)

在深度神经网络中,不同特征映射中的不同通道通常代表不同的对象。通道注意自适应地重新校准每个通道的权重,可以将其视为对象选择过程,从而确定需要注意的内容。空间注意将其视为对象在哪里的过程,从而确定对象的位置[16]。为了提高通道注意力和空间注意力的表示,许多研究者提出了不同的方案,例如

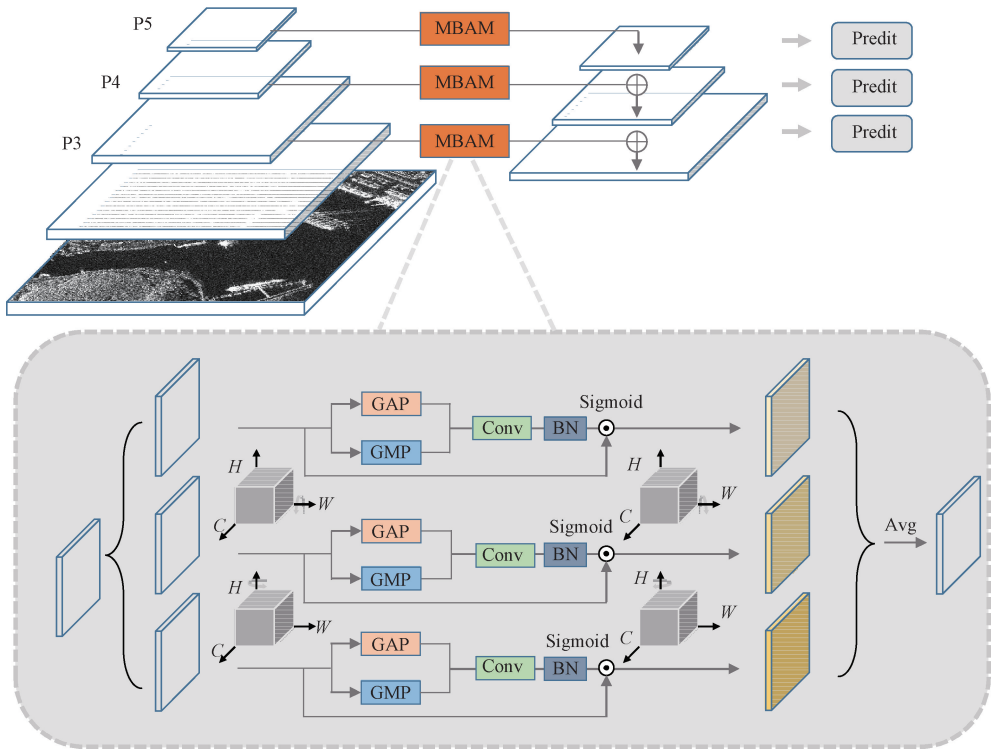

图 1　网络结构图

Fig. 1　Network structure diagram

SENet[17]通过全局平均池化来提取全局的空间信息,通过两个全连接层捕捉通道之间的关系,但是 SENet 只在通道方面进行了注意力的表示,忽略了空间维度。BAM[18]分别在通道和空间两个维度进行操作,利用全局平均池化提取通道间的信息,在空间维度为了有效的利用上下文信息,扩大感受野,结合了扩张卷积和全连接层,但是 BAM 在通道分支使用了全局平均池化,可能会丢失更有用的全局信息;CBAM[19]在通道分支分别使用了全局平均池化和全局最大池化,但是没有考虑多维度交互的情况,受 Triplte Attentio[20]启发本文提出了一种全新的注意力多分支注意力模块(multiple branch aattention moudle,MBAM),如图 2 所示,该模块将不同维度的信息融合起来在整个空间对检测目标进行精确定位。与 Triplet- Attention 不同的是使用全局平均池化和全局最大池化更能平衡 SAR 图像的特征信息。

在日常生活中看到一个场景时,会将注意力集中在有区别的区域上,并快速处理这些区域。上述过程可表述为:

$$Attention = f(g(x),x) \tag{1}$$

其中,$g(x)$ 代表产生注意力的过程,x 代表输入的特征信息,维度大小为 (c,h,w),$f(g(x),x)$ 表示基于注意力 $g(x)$ 处理输入 x 的方法。将 x 进行维度变换可以分别得到 (h,c,w) 和 (w,h,c) 两个不同大小维度的特征信息,所以对于 MBAM 有 3 个分支,分别为 (c,h,w),(h,c,w),(w,h,c)。分别用 x_1、x_2、x_3 表示,对于 x_1 进行如下操作:

$$g(x)_1 = \sigma(MLP(GAP(x_1)) + MLP(GMP(x_1))) \tag{2}$$

其中,GAP 和 GMP 分别表示全局平均池化和全局最大池化,MLP 表示一个卷积层,σ 表示 sigmoid 激活函数。

对于 x_2:

$$g(x)_2 = \sigma(Conv(cat(GAP(x_2),(GMP(x_2))))) \tag{3}$$

$$f(g(x),x)_2 = g(x)_2 x \tag{4}$$

对于 x_3,与 x_2 类似:

$$g(x)_3 = \sigma(Conv(cat(GAP(x_3),(GMP(x_3))))) \tag{5}$$

$$f(g(x),x)_3 = g(x)_3 x \tag{6}$$

最后将 3 个分支的特征进行平均:

$$x = \frac{1}{3}(g(x_1) + g(x_2) + g(x_3)) \tag{7}$$

由此,可以得到最后的特征输出 x 层。其中 cat 是将两个特征进行拼接操作。

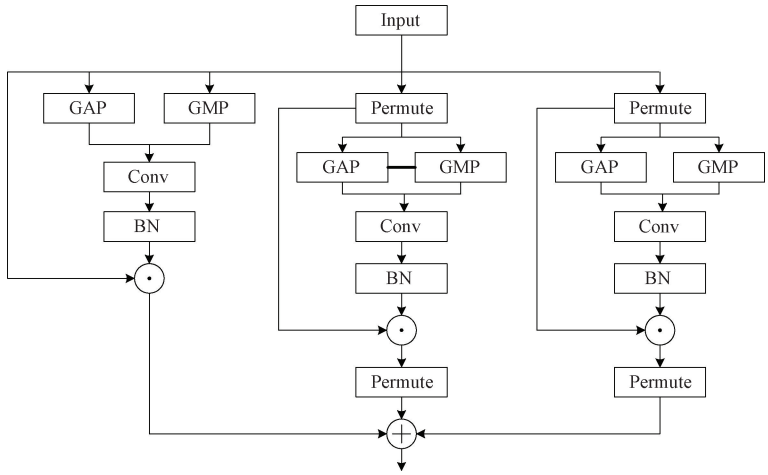

图2　MBAM结构

Fig. 2　MBAM Structure

2　旋转目标检测

近年来,旋转目标检测在文本检测、航空图像检测应用广泛,在面对检测目标密集并且明显具有一定的倾斜角度时,旋转目标检测具有更好的效果,在SAR图像中,舰船目标通常也以一定的倾斜角度出现,尤其是在靠岸目标排列时,旋转目标检测会减少由于目标重合对检测结果的影响。

尽管之前的旋转检测方法已经取得了满意的结果,但是仍然存在一些问题,具体来说是就是将角度作为回归问题引起边界不连续的问题[21-22]。因此,本文引入圆形光滑标签(CSL)将角度作为一个分类问题。

2.1　表示方法

如图3所示目标检测常用的旋转框表示方法一般有Opencv表示法、长边定义法等。以顺时针为正方向,检测框与x轴的锐角角度为θ,与x轴成锐角的这条边为w,另一条为h,所以Opencv表示法的参数有(x,y,w,h,θ),其中$\theta \in (0,90°)$。长边定义法将检测框的长边与x轴的角度定为θ,并且长边为h,短边为w,所以长边定义法的参数(x,y,w,h,θ),其中$\theta \in (-90°,90°)$。本文将采用长边定义法来表示旋转框。

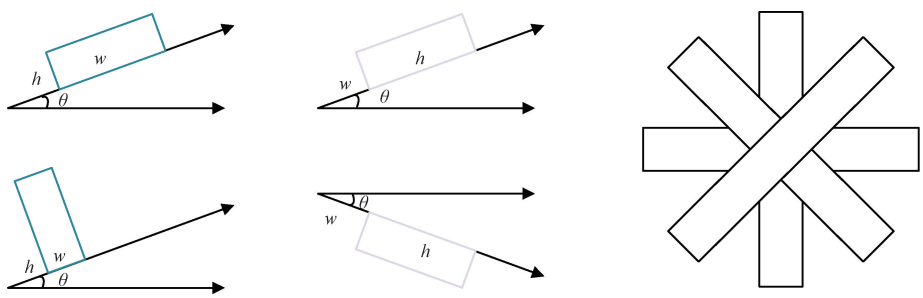

图3　旋转框表示方法

Fig. 3　Representation method of rotating box

2.2　圆形光滑标签(CSL)

角度基于回归方法主要带来边界不连续的问题,主要包括角度的周期性和边框的可交换性。前者的主要原因是角度参数的周期性,而后者与边界框的定义有关。一般来说,根本的原因是理想的预测结果超出了定义的范围,会导致边框处的损失急剧增加,增加了边界框回归的难度。因此使用CSL[23]来解决问题,CSL将角度预测从回归问题转化为一个高精度的分类问题,CSL主要是一个周期性的循环编码,如图4所示。

CSL的表达式如下:

$$CSL(x)=\begin{cases} g(x), \theta - r < x < \theta + r \\ 0, \text{其他} \end{cases} \tag{8}$$

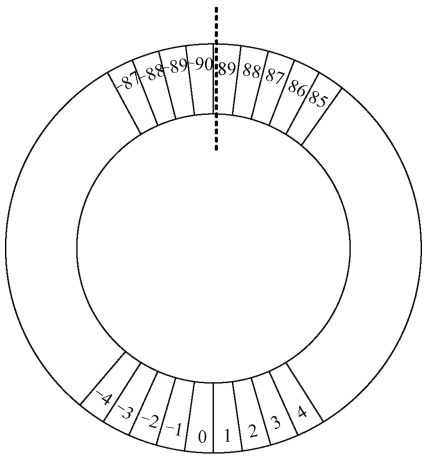

图 4　圆形光滑标签

Fig. 4　Circular smooth label

其中，$g(x)$ 是窗口函数，默认为高斯函数，r 是窗口函数的半径，默认 $r=1$，θ 表示当前边界框的旋转角度。

2.3　损失函数

对于边界框回归的好坏应该考虑 3 个重要的因素，既重合面积，中心点距离和长宽的比例。因此，本文采用 CIOU loss 来回归边界框，定义如下：

$$L_{CIOU}=1-IOU+\frac{\rho^2(b,b^{gt})}{c^2}+\alpha v \tag{9}$$

其中，$\rho^2(b,b^{gt})$ 代表了预测框和真实框中心点的欧氏距离。c 代表能够同时包含预测框和真实框的最小闭包区域的对角线距离。α 是权重系数，v 用来衡量两个矩形框宽和高相对比例的一致性：

$$v=\frac{4}{\pi^2}\left(\arctan\frac{w^{gt}}{h^{gt}}-\arctan\frac{w}{h}\right)^2 \tag{10}$$

$$\alpha=\frac{v}{(1-IOU)+v} \tag{11}$$

对于分类损失，本文采用交叉熵损失函数：

$$L=\frac{1}{N}\sum_{i-1}^{N}\left[y_i\ln(\sigma(x_i))+(1-y_i)\ln(1-\sigma(x_i))\right] \tag{12}$$

其中，$\sigma(x_i)$ 是模型预测样本为正例的概率，y_i 为样本标签，如果样本属于正例，取值为 1，否则取值为 0。所以总的损失函数部分由回归损失、CSL 分类损失、类别损失 3 部分组成，可表示为：

$$L=\frac{\lambda_1}{N}\sum_{1}^{N}obj\cdot\sum_{j\in(x,y,w,h,\theta_{reg})}L_{reg}(b'_{nj},b_{nj})+\frac{\lambda_2}{N}\sum_{1}^{N}L_{CSL}(\theta'_n,\theta)+\frac{\lambda_3}{N}\sum_{1}^{N}L_{cls}(p_n,t_n) \tag{13}$$

其中，N 为正样本的数量，obj 表示前景或者是背景，当是前景时为 1，背景时为 0。b'_{nj} 表示预测框的偏移量，b_{nj} 表示真实框。θ'_n 是预测的角度，θ 是真实的角度。t_n 是真实的标签，p_n 为预测的类别概率。

3　实验与分析

本文所有的对比实验均在 mmdetection 平台训练，操作系统为 Ubuntu20.04，深度学习框架为 Pytorch1.8，，并在 CUDA11.2 和 cudnn8.1 进行加速训练。计算机配置为 Intel(R) Core(TM) i7-10700 CPU @ 2.90GHz，显卡为 NVIDIA RTX 3090，24 GB 显存。

3.1　数据集

SSDD+[24] 数据集是在 2017 年发布的用于 SAR 图像检测任务的数据集，数据集具有 1 160 张 SAR 图像，共计 2 456 个船舶目标。

HRSID[25] 据集是电子科技大学在 2020 年 1 月发布数据集，HRSID 是高分辨率 SAR 图像中用于船舶检测、语义分割和实例分割任务的数据集。该数据集共包含 5 604 张高分辨率 SAR 图像和 16 951 个舰船目标。HRSID 数据集借鉴了 COCO 数据集的构建过程，包括不同分辨率的 SAR 图像，具有极化、海况、海域和沿海港口等不同的场景。

3.2　网络参数设置

本文初始学习率设置为 0.02，采用动量优化器，动量值设为 0.843。NMS 和预测概率的阈值设为 0.5，损失函数的权重. $\lambda_1,\lambda_2,\lambda_3$. 。分别 1.0，0.5，1.0，迭代次数为 200 epochs。

3.3　实验结果对比

本文分别在 SSDD+和 HRSID 两个数据集上进行了实验，实验结果如表 1 所示，YOLOv5 是不加注意力模块 MBAM 和 CSL 的检测结果，YOLOv5(CSL)是加了圆形光滑标签的结果，YOLOv5(CSL+MBAM)是最终的检测结果，在 SSDD 数据集中 YOLOv5(CSL)相对于 YOLOv5 检测指标分别提高了 0.47%，1.40%，1.98%，YOLOv5(MBAM)分别提高了 0.34%、0.81%、1.24%，YOLOv5(CSL+MBAM)检测指标提高了 1.56%、2.57%、2.11%。在 HRSID 数据集中，引入 CSL 检测指标分别提高了 0.43%，0.66%，0.69%，引入 MBAM 检测指标提高，0.86%，0.23%，1.05%，引入 CSL+MBAM 检测指标提高了 1.62%、1.29%、2.58%，由此可以看出，分别引入注意力机制和 CSL 都一定程度提高了检测的精度。

改进前后的检测结果的对比如图 5 所示，第 1 行为标注结果，第 2 行为改进前的结果，第 3 行为改进后的检测结果，可以发现，不论是在近岸的检测还是远岸的检测结果中，都会出现漏检误检的情况，而改进后的方法，对于舰船目标的检测更为准确，出现误检和漏检的情况都更少。图中虚线标记的为漏检的舰船目标，实线标记的

表1　添加不同方法的检测结果对比

Table 1　Add the comparison of detection results of different methods

方法	SSDD+			HRSID			FPS	Size
	Recall	Pre	mAP	Recall	Pre	mAP		
YOLOV5	85.86	87.56	84.32	80.11	83.69	81.33	20.9	179 M
YOLOv5(CSL)	86.33	88.96	86.30	80.54	84.35	82.02	20.9	185 M
YOLOv5(MBAM)	86.21	88.37	85.56	80.97	83.92	82.38	20.1	181 M
YOLOv5(CSL+MBAM)	87.42	90.13	86.43	81.73	84.98	83.91	20.1	187 M

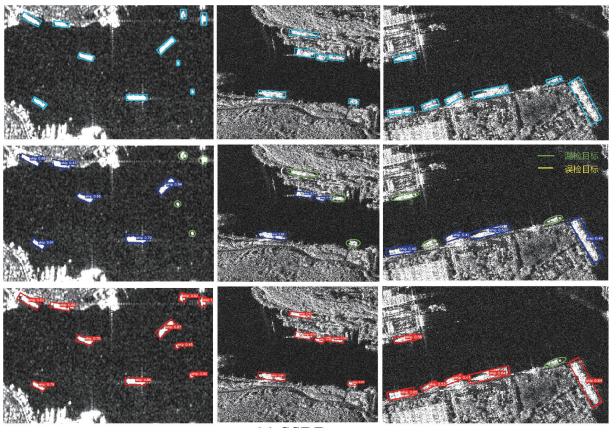

(a) SSDD+

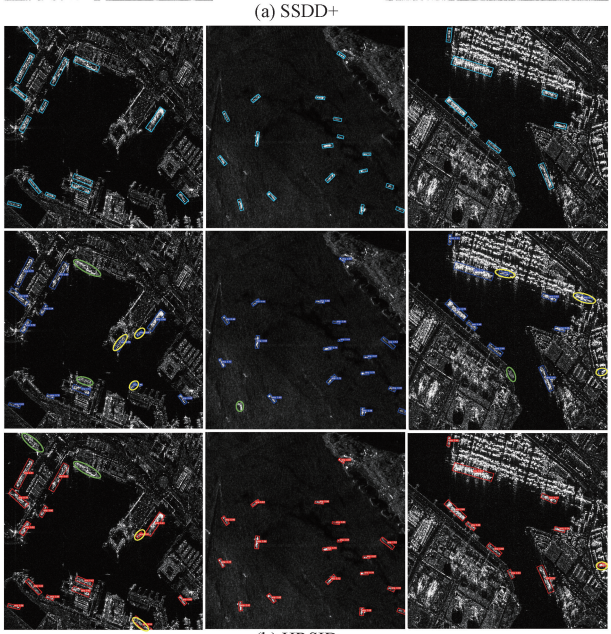

(b) HRSID

图5　改进前后检测结果对比

Fig. 5　Comparison of detection results before and after improvement

为误检的舰船目标。

利用SSDD+和HRSID数据集与其他算法进行了对比实验,进一步验证本文算法的有效性。由表2能够清楚的看出来,本文的方法在与目前最好的算法相比,在mAP基本持平的情况下,模型参数更小,检测速度更快。

表2　与不同算法的结果对比

Table 2　Compares the results with different algorithms

方法	SSDD+ mAP	HRSID mAP	FPS	Size
R-RtinaNet	84.38	82.65	13.8	295
ReDet	85.42	83.98	11.8	378
S2aNet	85.65	84.28	17.3	331
R3Det	**86.83**	**84.63**	12.6	333
Ours	**86.43**	**83.91**	**20.1**	**187**

为了进一步探索影响检测mAP结果的因素,将数据集分为远岸(Offshore)和近岸(Inshore)两类。近岸目标所处的环境更为复杂,检测难度更高,这部分目标检测结果的好坏可能直接影响最终的检测结果。如图6的检测结果更好地验证了本文的猜想,在远岸场景下,不同的算法对这类目标的检测结果并没有拉开大的差距,都具有非常好的结果;但是在对近岸这类目标,本文的方法相对于其他算法具有明显优势,能够在复杂环境中更好地检测出目标。

图7为本文算法的部分检测结果可以看出,在不同场景下边界框对于目标的的包围都是比较准确的,不论是远海的小尺度目标还是近海的大目标,本文的方法在角度的分类过程中,都能够较好地预测角度的类别,从而准确的挑选出最优的边界框。

4　结　论

针对SAR图像检测经常出现误检,漏检等问题,本文提出了一种全新的注意力模块MBAM,将其插入FPN网络的前向通道,把底层的语义信息和浅层的位置信息进行多维度的融合,有效解决漏检误检问题,并且结合旋转目标检测,引入圆形光滑标签,将角度回归问题转为角度分类问题,解决边界不连续所带来损失增大的问题。最后在不同的数据集上进行对比实验,进一步证明本文方法在精度持平的情况下,检测速度具有更大优势,能够满足未来检测实时性的要求。

参考文献

[1]　李永刚, 朱卫纲, 黄琼男. SAR图像目标检测方法综述[J]. 兵工自动化, 2021, 40(12):91-96.

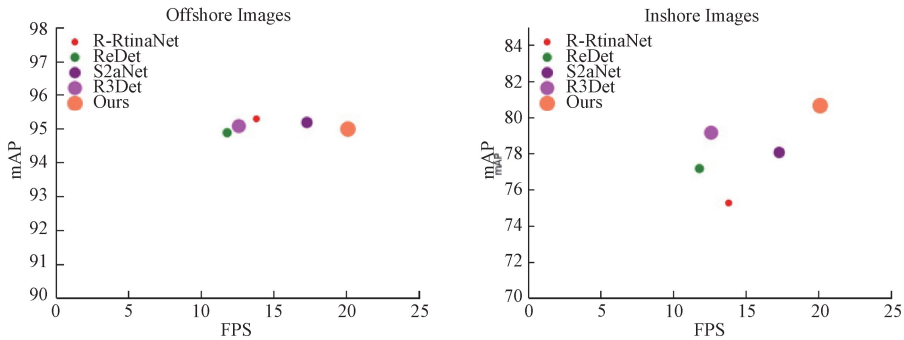

(a) SSDD+数据集对比
(a) SSDD+ data set comparison

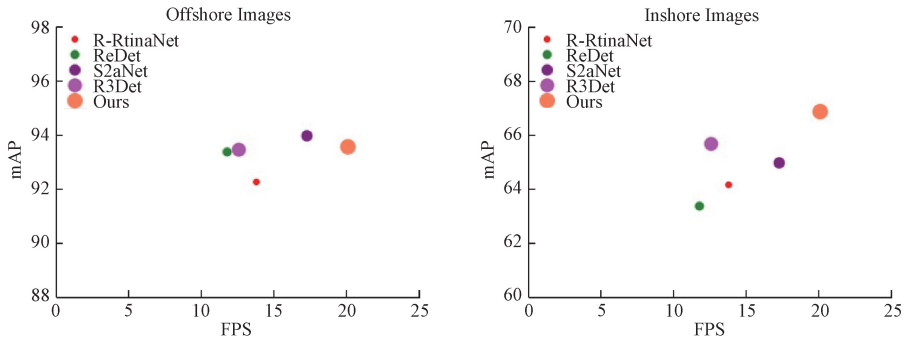

(b) HRSID数据集对比
(b) HRSID data set comparison

图 6　近岸场景与远岸场景检测对比

Fig. 6　Detection comparison between inshore scene offshore scene

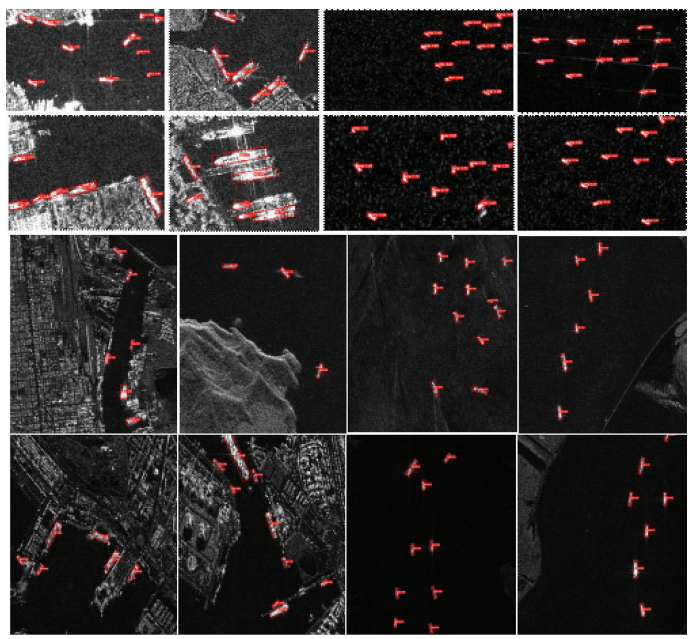

图 7　部分检测结果

Fig. 7　Partial detection results

LI Y G, ZHU W G, HUANG Q N. Review of SAR image target detection method [J]. Ordnance Industry Automation, 2021, 40(12):91-96.

[2] WANG C, BI F, ZHANG W, et al. An intensity-space domain CFAR method for ship detection in HR SAR images[J]. IEEE Geoscience & Remote Sensing Letters,

2017, 14(4):529-533.

[3] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]. IEEE Computer Society. IEEE Computer Society, 2013.

[4] GIRSHICK R. Fast R-CNN [J]. 2015 IEEE International Conference on Computer Vision (ICCV), 2015, DOI: 10.1109/ICCV.2015.169.

[5] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6):1137-1149.

[6] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[J]. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016:779-788.

[7] REDMON J, FARHADI A. YOLO9000: Better, faster, stronger[J]. IEEE, 2017:6517-6525.

[8] REDMON J, FARHADI A. YOLOv3: An incremental improvement[J]. ArXiv Preprint,2018, arXiv:1804.02767.

[9] BOCHKOVSKIY A, WANG C Y, LIAO H. YOLOv4: Optimal speed and accuracy of object detection [J]. ArXiv Preprint,2020, arXiv:2004.10934.

[10] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector[J]. Springer, Cham, 2016,DOI: 10.1007/978-3-319-46448-0_2.

[11] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017:2999-3007.

[12] 史朋飞, 韩松, 倪建军, 等. 结合数据增强和改进 YOLOv4 的水下目标检测算法[J]. 电子测量与仪器学报, 2022,36(3):113-121.
SHI P F, HAN S, NI J J, et al. Underwater object detection algorithm combining data enhancement and improved YOLOv4 [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(3): 113-121.

[13] GUO H, YANG X, WANG N, et al. A CenterNet++ model for ship detection in SAR images [J]. Pattern Recognition, 2021, 112(7):107787.

[14] 吕禾丰, 陆华才. 基于 YOLOv5 算法的交通标志识别技术研究[J]. 电子测量与仪器学报, 2021, 35(10): 137-144.
LUY H F, LU H C. Research on traffic sign recognition technology based on YOLOv5 algorithm[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(10):137-144.

[15] ZHANG T, ZHANG X, KE X. Quad-FPN: A novel quad feature pyramid network for SAR ship detection[J]. Remote Sensing, 2021, 13(14):2771.

[16] 赵琰, 赵凌君, 匡纲要. 基于注意力机制特征融合网络的 SAR 图像飞机目标快速检测[J]. 电子学报, 2021, 49(9):1665-1674.
ZHAO Y, ZHAO L J, KUANG G Y. Attention feature fusion network for rapid aircraft detection in SAR images[J]. Acta Electronica Sinica, 2021, 49(9): 1665-1674.

[17] JIE H, LI S, GANG S, et al. Squeeze-and-excitation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, DOI: 10.1109/TPAMI.2019.2913372.

[18] PARK J, WOO S, LEE J Y, et al. BAM: Bottleneck attention module [J]. ArXiv Preprint, 2018, arXiv:1807.06514.

[19] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module [J]. Springer, Cham, 2018,DOI:10.1007/978-3-030-01234-2_1.

[20] MISRA D, NALAMADA T, ARASANIPALAI A U, et al. Rotate to attend: Convolutional triplet attention module [J]. Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision (WACV), 2021:3139-3148.

[21] QIAN W, YANG X, PENG S, et al. Learning modulated loss for rotated object detection [J]. ArXiv Preprint, 2019,arXiv:1911.08299.

[22] YANG X, YANG J, YAN J, et al. SCRDet: Towards more robust detection for small, cluttered and rotated objects[C]. 2019 IEEE/CVF International Conference on Computer Vision (ICCV). IEEE, 2019.

[23] YANG X, YAN J. Arbitrary-oriented object detection with circular smooth label[J]. Computer Vision-ECCV 2020, DOI: 10.1007/978-3-030-58598-3_40.

[24] 李健伟, 曲长文, 彭书娟,等. 基于卷积神经网络的 SAR 图像舰船目标检测[J]. 系统工程与电子技术, 2018, 40(9):1593-1595.
LI W J, QU CH W, PENG SH J, et al. Ship detection in SAR images based on convolutional neural network[J]. Systems Engineering and Electronics. 2018, 40(9):1593-1595.

[25] WEI S, ZENG X, QU Q, et al. HRSID: A high-resolution SAR images dataset for ship detection and instance segmentation[J]. IEEE Access, 2020, DOI: 10.1109/ACCESS.2020.3005861.

作者简介

胡欣，1997 年于西安工业学院获得学士学位，2002 年于兵科院 212 研究所获得硕士学位，2008 年于西北工业大学获得博士学位。现为长安大学副教授，主要研究方向为电网大数据处理、机器学习与深度学习。

E-mail：huxin@ chd. edu. cn

Hu Xin received her B. Sc. degree from Xi′an Technology University in 1997, M. Sc. degree from China North Industries Group Corporation Limited in 2002 and Ph. D. degree from Northwestern Polytechnical University in 2008. Now she is an associate professor at Chang′an University. Her main research interests include power grid big data processing, machine learning and deep learning.

马丽军（通信作者），2020 年于西北民族大学获得学士学位，现为长安大学硕士生，主要研究方向为计算机视觉。

E-mail：1127244933@ qq. com

Ma Lijun (Corresponding author) received his B. Sc. degree from Northwest Minzu University in 2020. Now he is a M. Sc. candidate at Chang′an University. His main research interest includes computer vision.