

结合特征融合和注意力机制的 SAR 舰船检测算法^{*}

李 波 李志康 周钰彬

(辽宁工业大学电子与信息工程学院 锦州 121001)

摘 要: 针对现有的合成孔径雷达目标检测算法仅利用图像底层特征进行检测存在的对小尺度舰船目标的检测率较低问题,提出一种结合特征融合和注意力机制的目标检测算法。面向 SAR 舰船目标检测,在原始主干网络 SSD 目标检测算法的基础上,引入注意力机制模块、不同层次的特征图进行特征融合、对含有小尺度目标的图像进行过采样还通过多次复制粘贴小目标实现数据增广。实验通过对 SAR 舰船图像数据集的大量训练和测试,结果表明本文算法能有效提升对舰船目标的综合检测性能,在公开 SAR 舰船目标检测数据集上平均精度可以达到 94.16%。

关键词: 合成孔径雷达;舰船检测;特征融合;注意力机制

中图分类号: TN911.73 **文献标识码:** A **国家标准学科分类代码:** 510.4010

SAR ship detection algorithm combining feature fusion and attention mechanism

Li Bo Li Zhikang Zhou Yubin

(School of Electronic and Information Engineering, Liaoning University of Technology, Jinzhou 121001, China)

Abstract: In order to solve the problem that the existing SAR target detection algorithm only uses the underlying features of the image for detection, and the detection rate of small-scale ship targets is low, an object detection algorithm combining feature fusion and attention mechanism was proposed. For SAR ship-target detection, on the basis of the original backbone network SSD target detection algorithm, the attention mechanism module is introduced, the feature maps at different levels are fused with features, the images containing small-scale targets are oversampled, and the data augmentation is achieved by copying and pasting small targets multiple times. Through a large number of training and testing of SAR ship image datasets, the results show that the proposed algorithm can effectively improve the comprehensive detection performance of ship targets, and the mean average precision can reach 94.16% on the public SAR ship target detection dataset.

Keywords: synthetic aperture radar; ship detection; feature fusion; attention mechanism

0 引 言

合成孔径雷达(synthetic aperture radar, SAR)是遥感领域不可缺少的重要监测工具。它是一种有源微波成像传感器,利用全天候、全天时成像和侦察能力,是获取 SAR 图像的主要途径,可提供不受天气和照明条件影响的高分辨率图像,广泛应用于许多行业。特别是在 SAR 舰船目标检测方面,它能高效获取各种海况下的舰船信息。

随着深度学习的迅速发展,基于卷积神经网络(convolutional neural networks, CNN)的方法用于 SAR 目标检测成为主流的研究趋势^[1]。CNN 的计算属性在应对大量参数运算及更新方面具有优势,相比于传统的 SAR 舰

船目标检测算法具有更好的检测性能。基于深度学习的目标检测算法包含单阶段和双阶段两种。以你只看一次(you only look once, YOLO)系列和单次多盒探测器(single shot multi box detector, SSD)为代表的单阶段目标检测算法在保证检测精度的前提下效率更高,符合 SAR 目标检测的实际需要,因此,基于单阶段目标检测算法应用于 SAR 舰船目标检测已有相关研究。Ge 等^[2]采用双边特征金字塔结构融合多尺度特征,增加了各尺度特征的学习权重,加强了浅层特征的表达能力,实现了模型检测性能的提升。Yang 等^[3]提出了以 IMNet 为主干的特征提取网络,增强了特征提取能力,以较少的参数实现多了尺度特征的融合。李健伟等^[4]采用特征图金字塔网络改进了 SSD 目标检测

算法,兼顾了底层信息与高层信息。杨龙等^[5]在 SSD 的基础上融合了上下文信息,分析了不同特征图之间的关联性,保证了检测效率。苏娟等^[6]提出了一种浅层特征增强方法,优化了网络对小尺寸舰船目标的适应能力。张晓玲等^[7]提出了由深度卷积和点状卷积组成的深度分离 CNN,能解耦通道相关性和空间相关性,减少了计算量。Feng 等^[8]改进了 SSD 的浅层网络结构,融合了不同模块的网络特征,使模型检测性能得到改善。陈洋等^[9]通过融合多尺度信息与注意力机制优化了模型,提升了 SAR 舰船图像的检测精度。

综上,单阶段目标检测算法应用于 SAR 舰船目标的检测的研究取得了显著进展,但在基于 SSD^[10]的检测算法中,仍存在小目标检测能力和模型泛化性较弱的问题。若能优化特征提取层提取的目标特征并充分利用这些特征图,可有效解决问题。因此,本文对 SSD 目标检测算法进行了适应性改进。首先,嵌入注意力机制使模型更关注舰船目标,以减少复杂背景及杂波对模型检测的干扰。其次,对包含小尺度目标图像进行增强和过采样,使模型对小尺度目标的检测能力进一步提升。最后,引入特征融合模块使深浅特征层提取的特征信息相互融合并充分利用,改进后的算法提升了 SAR 舰船目标的检测性能。

1 改进目标检测算法

用于 SAR 舰船目标检测的 SSD300 可视为一类前馈的 CNN。它首先产生固定大小的默认框集合,再利用不同层次的特征图来进行位置回归与类别预测,最后由非极大值抑制算法对每类别预测到的所有先验框集合进行筛选,去除概率较低的边框,其结构模型如图 1 所示。可以看出,

原始的 SSD 目标检测算法使用较浅的视觉几何组(visual geometry group, VGG)提取特征,无法提取目标较深层次的语义信息,对图像中的每个位置都使用相同的感受野和卷积核,导致对于较小、较模糊或较深的目标检测效果较差。




图 1 传统 SSD 目标检测算法

针对 SAR 舰船目标检测,本文对 SSD 目标检测算法改进,改进算法结构如图 2 所示。其中,输入图片的大小为 300×300 。首先,将输入图片经过卷积层和池化层将图像尺寸调整为 $75 \times 75 \times 64$ 。随后,接入 ResNet50^[11]网络部分提取特征,本文选择 ResNet50 的第 2 层到第 4 层进行特征提取,在 ResNet50 的第 3 层和第 4 层提取到的特征图后添加注意力机制,然后直接输出到卷积预测层,并在第 4 层之后进行 4 次连续下采样得到 4 组不同尺寸的特征层。在特征提取层 4 和 5 输出之前,分别将特征提取层 4 和 2,特征提取层 5 和 1 进行特征融合后添加至卷积预测层,增强模型对小目标的检测能力。上述特征图通过卷积预测层后,先将背景预测框过滤删除,再将所有预测框中置信度最大的作为候选框,筛选去除其他置信度较低的预测框,本文置信度阈值设为 0.5。对剩余预测框解码处理,得到位置参数,并根据置信度降序排列,再通过非极大值抑制(non-maximal suppression, NMS)算法将重复的检测结果合并到一个结果中,输出最终检测结果。

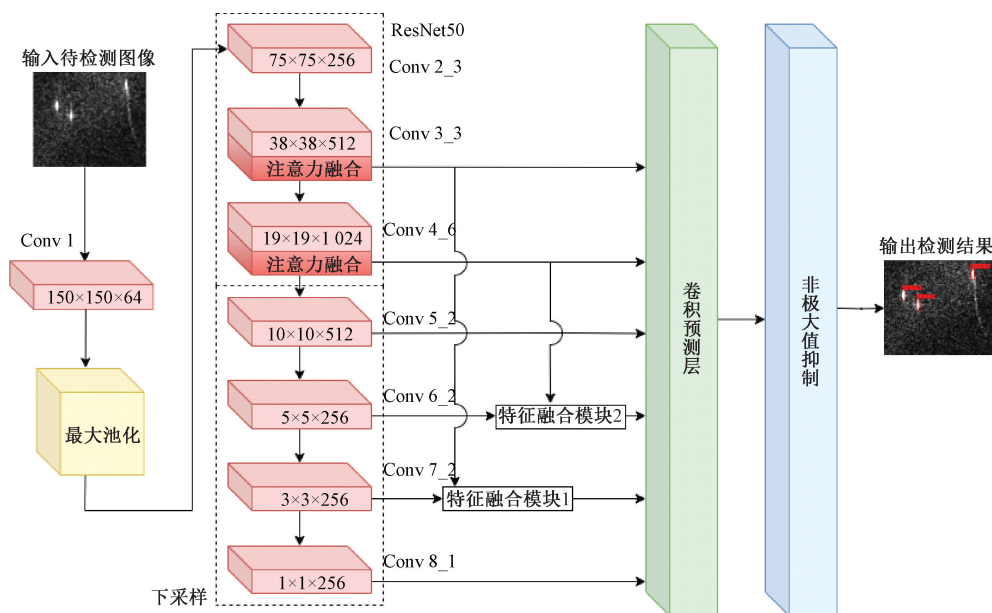


图 2 改进目标检测算法结构

2 改进模块介绍

2.1 过采样和数据增强

对 SAR 舰船目标检测而言,常见的数据集中只有部分图像中包含小尺度目标,样本数量不均衡,导致小目标在图像中的位置分布有限,SSD 目标检测算法在位置上泛化能力较差。在实际的检测图像中,小目标可能出现在训练集中未出现的位置,缺乏背景多样性^[12]。本文通过对包含小目标物体的图像过采样和复制粘贴小目标对模型训练进行优化。

在构造每个 Batch 时,本文由 SSDD^[13]数据集的真实框数据对包含小目标物体的图像进行筛选,对其重复采样,提高小目标检测的性能。同时,数据集所提供的实例分割掩码允许从任何对象的原始位置复制一个对象,并将副本粘贴到不同的位置。通过增加每张图像中的小目标数量,使匹配的锚点数量增加,提高小物体在训练过程中对计算损失函数的贡献。在将对象粘贴到新的位置前,对其施加旋转变换。由于在粘贴的过程中只考虑非遮挡物体,粘贴不相交的分割掩码和中间的未见部分会导致不真实的图像。为确保新粘贴的对象不与任何现有的对象发生重叠,距离图像边界至少为 5 个像素,图像旋转前后的坐标映射可表示为:

$$\begin{cases} W' = W \cos \theta + Q \sin \theta \\ Q' = -W \sin \theta + Q \cos \theta \end{cases} \quad (1)$$

式中:\$(W, Q)\$为旋转前的坐标,\$(W', Q')\$为旋转后的坐标, \$\theta\$ 为旋转角度,本文取 \$30^\circ\$。

2.2 优化局部注意力机制

本文引入一种高效局部注意力机制 (efficient local attention, ELA)^[14]于目标检测算法,该方法结合一维卷积和组归一化 (group normalization, GN) 特征增强技术,通过高效地编码两个一维位置特征图来实现感兴趣区域的准确定位,而无需降维,同时达到轻量级的实现。高效局部注意力机制的结构如图 3 所示。

本文在特征提取层 1 和特征提取层 2 之后加入高效局部注意力机制,以特征提取层 1 为例介绍本文注意力机制具体实现过程。经过特征提取层 1 之后得到的特征图尺寸为 \$38 \times 38 \times 512\$, 本文所用注意力机制首先对特征图水平和垂直方向上分别进行平均池化操作,将特征图处理为沿水平方向上的尺寸为 \$38 \times 1 \times 512\$ 的特征图切片和沿垂直方向上的尺寸为 \$1 \times 38 \times 512\$ 的特征图切片,得到了所有通道在高度 \$h\$ 处的输出以及所有通道在宽度 \$w\$ 处的输出表示:

$$z_c^h(h) = \frac{1}{H} \sum_{0 \leq i < H} x_c(h, i) \quad (2)$$

$$z_c^w(w) = \frac{1}{W} \sum_{0 \leq j < W} x_c(j, w) \quad (3)$$

式中: \$x_c(h, i)\$ 和 \$x_c(j, w)\$ 分别表示输入特征图的 \$c\$ 通道

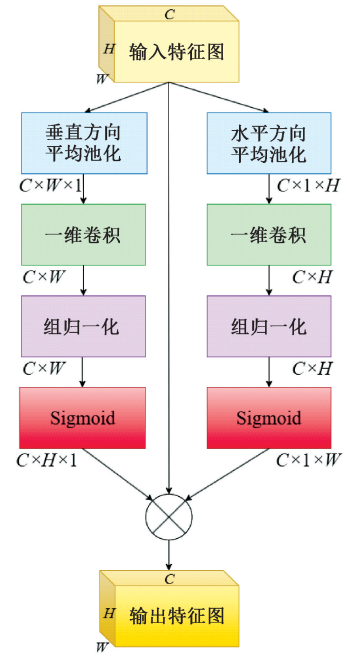


图 3 高效局部注意力机制结构

中第 \$h\$ 行 \$i\$ 列和第 \$j\$ 行 \$w\$ 列的值, \$z_c^h(h)\$ 和 \$z_c^w(w)\$ 分别表示输入特征图 \$c\$ 通道中 \$h\$ 列和 \$w\$ 行进行平均池化操作后的值。所得的输出不仅捕获了全局的感受野,而且获取了目标的位置信息。

考虑到每个通道内的序列信息都是一维的,本文选择更擅长处理序列信号且更加轻量级的一维卷积来进行处理,以增强定位信息嵌入的交互能力,使处理后的特征图能准确定位。经一维卷积操作后将水平和垂直方向的两切片处理为两个 \$38 \times 512\$ 的特征图,随后,利用组归一化来处理增强的位置信息,并由 Sigmoid 非线性激活函数得到位置注意力在水平和垂直方向上的定义:

$$y^h = \sigma(G_n(F_h(z_c^h))) \quad (4)$$

$$y^w = \sigma(G_n(F_w(z_c^w))) \quad (5)$$

式中: \$\sigma\$ 为非线性激活函数; \$G_n\$ 表示组归一化操作; \$F_h\$ 和 \$F_w\$ 表示一维卷积,由此得到的位置注意力在水平和垂直方向上的表示,分别记为 \$y^h\$ 和 \$y^w\$。最后将得到的注意力权重与原输入特征图 \$x_c\$ 进行特征级融合得到注意力机制的输出

$$Y = x_c \times y^h \times y^w \quad (6)$$

在特征提取层 2 后加入的注意力机制处理过程同上。经局部高效注意力机制处理后的特征图能合理利用 SAR 舰船图像的空间和通道信息,使模型更关注待检测目标,有助于模型检测性的提升。

2.3 深浅层特征融合模块

在 SAR 舰船目标检测过程中,SSD 目标检测算法对小目标的检测性能较差,原因是各特征提取层提取不同尺寸的特征图之后,特征图之间是相互独立的。当使用浅层

特征进行小目标预测时,缺乏深层特征的语义特征,而使用深层特征进行目标检测时,又忽略了浅层特征的细节信息,这就导致检测模型不能兼顾各特征提取层的优点,所以对小目标的检测效果较差。为综合不同特征层提取的特征图的优势,本文使用特征融合模块对浅层特征图和深层特征图进行融合。图 4 给出了特征融合模块 1 的结构。

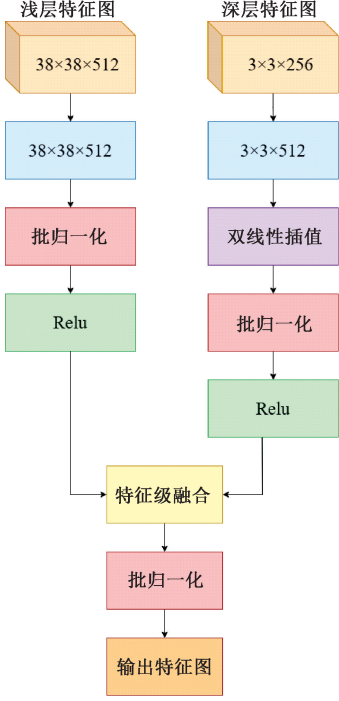


图 4 特征融合模块结构

在特征融合模块 1 中,浅层特征图尺寸为 $38 \times 38 \times 512$,深层特征图尺寸为 $3 \times 3 \times 256$ 。由于两特征图大小和通道数均不相同,因此在特征融合前须进行调整。首先,将深层特征图通过 512 个 $1 \times 1 \times 256$ 的卷积核将通道数调整为 512。然后,采用双线性插值的方法上采样,将两特征图调整为相同的尺寸和通道数,以实现特征融合。本文所采用的上采样方法为双线性插值,在完成图像的尺寸变换的同时,充分保留图像的平滑性和细节。假定在原图像中坐标 (x, y) 处插值,该坐标落在 4 个最近的邻像素 $(x_1, y_1), (x_2, y_1), (x_1, y_2)$ 和 (x_2, y_2) 之间,则 4 个最近邻像素位置的像素分别为 $f(x_1, y_1), f(x_2, y_1), f(x_1, y_2)$ 和 $f(x_2, y_2)$,水平方向上的两个中间值定义为:

$$f_1(x) = \frac{(x_2 - x)f(x_1, y_1) + (x - x_1)f(x_2, y_1)}{x_2 - x_1} \quad (7)$$

$$f_2(x) = \frac{(x_2 - x)f(x_1, y_2) + (x - x_1)f(x_2, y_2)}{x_2 - x_1} \quad (8)$$

在垂直方向上对 $f_1(x)$ 和 $f_2(x)$ 进行线性插值:

$$f(x, y) = \frac{(y_2 - y)f_1(x) + (y - y_1)f_2(x)}{y_2 - y_1} \quad (9)$$

式中: $f(x, y)$ 为目标位置 (x, y) 处的像素。重复差值过程直到 38×38 的特征图所有位置均被填充。这样,插值后的特征图不仅具有与浅层特征图有相同的尺寸和通道数,还保留了原始特征图的关键信息,且特征图具有连续性。最后将特征图进行特征级融合,两特征图对应像素按照 1:1 的权重进行加权相加,得到最终的特征图。通过特征融合可利用深浅层特征提取层的优势,提取更有区分度和表达力的特征,从而改善模型的性能。

3 实验与结果分析

3.1 实验环境及参数配置

本文的实验环境:CPU 采用 IntelTM XeonTM CPU E5-2678 v3, GPU 采用 NVIDIA GeForce RTX 2080 Ti, 操作系统采用 Ubuntu18.04, 利用 CUDA 11.3 和 CUDNN8 加速训练, 学习框架为 pytorch, 项目实现使用 python 编程语言。相关实验参数的配置如下:网络训练批次为 500, 初始学习率为 0.002, 学习率在训练过程中每 50 个批次进行动态调整, 算法优化选择随机梯度下降, 动量为 0.937, 非极大值抑制阈值为 0.5。模型训练过程中损失曲线如图 5 所示。




图 5 训练过程损失变化曲线

3.2 数据集

本文选用的舰船检测数据集为已正确标注的公开 SAR 舰船目标检测数据集 SSDD。数据集包含 1 160 张 SAR 图像, 具有多极化模型、多分辨率、多舰船场景等特点。该数据集的 SAR 图像中共包含舰船 2 358 只, 舰船尺寸在 7×7 到 211×298 像素之间。本文对 SSDD 中包含小目标的图像进行筛选, 共计 343 张, 对这些图像进行复制粘贴小目标的数据增广操作, 使模型对于小目标检测有更好的性能。为达到最佳的实验效果, 设置数据集中训练集、验证集和测试集中的图像数比例为 7:2:1。

3.3 评价指标

本数值实验主要使用的评价指标有召回率 (Recall = $\frac{TP}{TP + FN}$)、精度 (Precision = $\frac{TP}{TP + FP}$)、平

均精度 (mean average precision, $mAP = \int_0^1 P(R) dR$)、每秒处理帧数 (frames per second, FPS)。其中, TP 为正确的舰船检测数目, FN 为漏检的舰船数目, FP 为虚警的舰船数目, R 为召回率, $P(R)$ 为精度召回率函数。

3.4 数据分析

1) 消融实验

为验证本文使用的局部高效注意力机制对模型的检测性能提升, 分别将挤压和激励网络 (squeeze-and-excitation net, SE Net)^[15], 卷积块注意力模块 (convolutional block attention module, CBAM)^[16], 协同注意力机制 (coordinate attention, CA)^[17] 和本文使用的注意力机制加入到网络中训练, 实验对比结果如图 6 所示。




图 6 不同注意力机制对模型性能影响

可以看出, 在加入注意力机制后, 检测模型的平均检测精度均得到提升。相较于其他 3 种注意力机制, 本文所用的注意力机制对模型的检测精度和性能稳定性的提升最大。SE Net 只考虑了通道维度上的注意力, 无法捕捉空间维度上的注意力, 在 SAR 图像的检测中表现较差; CBAM 从空间和通道两个方面对图像进行关注, 相较于 SE Net 有一定提升; CA 将通道注意力分解为两个一维特征编码过程, 分别沿两个空间方向聚合特征。可在一个空间方向上捕获远程依赖关系, 并在另一个空间方向上保留位置信息, 帮助模型定位和识别目标, 这种结构对模型检测精度的提升优于 CBAM; 本文所用的注意力机制进一步优化了 CA, 采用更适合操作序列信息的一维卷积, 用组归一化取代批归一化过程, 弥补了 CA 注意力生成过程复杂和泛化性不足的劣势, 平均准确率提升最大。

本文在传统的 SSD 目标检测算法的基础上, 使用 ResNet50 代替 VGG 进行特征提取, 在特征提取层 1 和特征提取层 2 之后添加注意力机制, 且在训练过程中对包含小目标图像施加复制粘贴小目标操作进行数据增广并采取过采样处理, 还在特征提取层 4 和特征提取层 5 的预测之前添加特征融合模块。各模块对模型性能的提升如表 1 所示。


表 1 不同模块对实验结果影响

过采样和数据增广	注意力机制	特征融合	mAP
			82.79
✓			83.49
✓	✓		88.87
✓		✓	89.40
✓	✓	✓	94.16

可以看出, 原始的 SSD 目标检测算法准确率较低。在对数据集进行数据增广和含小目标图像过采样操作后, 改善了数据集中包含小尺寸图像数量不足而导致模型泛化能力较差的情况, 模型对小目标的检测能力得到提升, mAP 提升至 82.79%。在此基础上再加入注意力机制抑制背景干扰, 更关注待检测目标, mAP 提升至 88.87%。加入特征融合层后, 使得模型同时关注深层特征提取层的语义信息和浅层特征提取层的细节信息, 充分利用了 SSD 中丰富的特征提取层, mAP 提升至 89.40%。由此, 将以上改进模块全部加入模型中可得最佳效果, mAP 达到 94.16%。

2) 检测效果分析

图 7 为可视化 SSDD 数据集部分检测结果对比, 包括受海杂波影响的 SAR 舰船 (图 7(a))、受斑点影响的 SAR 舰船 (图 7(b))、近岸小尺寸 SAR 舰船 (图 7(c))、河道内小尺寸 SAR 舰船 (图 7(d)) 及多目标小尺寸 SAR 舰船 (图 7(e))。图中左侧图片为传统的 SSD 算法检测出的估计框, 右侧图片为本文所提出的算法检测出的估计框。






图 7 检测结果对比

可以看出,在图 7(a)海杂波影响较大的图像中原始 SSD 算法出现左上角舰船目标的漏检和右下角海杂波误检,而本文算法能完整检测出所有目标;图 7(b)受斑点影响较严重,在噪声影响下未改进算法右侧两个舰船目标都未能检出,而本文算法抗斑点噪声干扰能力较强,所有目标都被检测到;图 7(c)的近岸地区舰船目标与岛屿特征相似,原始算法将右侧的近岸岛屿误检成舰船目标,而本文算法鲁棒性较强,未出现误检情况;图 7(d)所示的河道背景较复杂,岛屿和船舶目标距离很近的情况下不易区分,原始算法出现较多处的漏检和误检,而本文算法避免了上述情况;对于图 7(e)中多个小目标舰船,原始算法漏检了部分尺度偏小的舰船目标,而本文算法则全部检出。综上,本文提出的改进算法对海域、近岸地区以及港口地区等都有着较好的检测结果。

在数据集 SSDD 上,对比了本文算法与常用目标检测算法的结果。对照算法主要包括 Faster R-CNN^[18]、SSD、YOLOv5、HR-SD Net^[19],相关参数初值设置均保持一致。性能对比结果如表 2 所示。

表 2 目标检测算法性能对比

算法	Recall	Precision	mAP	FPS
Faster R-CNN	89.67	87.08	89.50	18
SSD	77.42	85.15	75.35	42
YOLOv5	76.10	93.62	76.68	46
HR-SD Net	86.54	96.38	87.40	32
本文算法	90.44	97.31	94.16	30

可以看出,本文算法对于 SAR 图像中舰船目标检测召回率达到 90.44%,相比于其他算法正确检出舰船目标的能力更强,检测精度达到 97.30%,虚警率极小,保证模型检测到的目标几乎都为待测目标,平均精度为 94.16%,远远领先于对比算法,证明本文算法在检测精度方面有最

好的综合性能。在检测速度方面,由于添加各改进模块使模型的复杂度略有增加,虽然检测速度相较于原始的单阶段目标检测算法有一定减慢,但对比双阶段目标检测算法和近年来的改进算法,其处理速度仍有提升。综上,本文算法在保证检测速度的前提下优化了检测精度,具有较高的 SAR 舰船目标的综合检测性能。

4 结 论

本文对原始的 SSD 目标检测算法进行了一系列的改进,包括过采样和复制粘贴小样本、嵌入注意力机制以及不同特征层之间加入特征融合模块,以期更适用于 SAR 图像的目标检测。从可视化检测结果和不同检测算法性能对比可知,本文算法增强了多场景下的 SAR 舰船目标的检测性能。虽然改进的算法相较于其他目标检测算法在检测精度方面得到提升,但在处理速度上还有提升空间。接下来,将对相关网络进行细节优化,进一步提高目标检测算法的效率。

参考文献

[1] WU X, HE X, TIAN S, et al. Review of ship target detection based on SAR images[C]. Xi'an: 2023 7th International Conference on Transportation Information and Safety(ICTIS),IEEE, 2023.

[2] GE R, MAO Y, LI S, et al. Research on ship small target detection in SAR image based on improved YOLO-v7[C]. Hangzhou:2023 International Applied Computational Electromagnetics Society Symposium (ACES-China),IEEE, 2023.

[3] YANG Y, JU Y, ZHOU Z. A super lightweight and efficient SAR image ship detector [J]. IEEE Geoscience and Remote Sensing Letters, 2023, 20: 1-5.

[4] 李健伟,曲长文,彭书娟. SAR 图像舰船目标联合检测与方向估计[J]. 武汉大学学报(信息科学版), 2019, 44(6): 901-907.

[5] 杨龙,苏娟,李响. 基于深度卷积神经网络的 SAR 舰船目标检测[J]. 系统工程与电子技术, 2019, 41(9): 1990-1997.

[6] 苏娟,杨龙,黄华,等. 用于 SAR 图像小目标舰船检测的改进 SSD 算法[J]. 系统工程与电子技术, 2020, 42(5): 1026-1034.

[7] 张晓玲,张天文,师君,等. 基于深度分离卷积神经网络的高速高精度 SAR 舰船检测[J]. 雷达学报, 2019, 8(6): 841-851.

[8] FENG M, PENG L. Research on ship detection in the SAR image algorithm based on improved SSD[C]. Xiamen:2021 4th International Conference on Artificial Intelligence and Pattern Recognition, 2021.

- [9] 陈洋, 张明, 杨立东, 等. 一种基于改进 YOLOv4 的 SAR 舰船检测算法[J]. 电子测量技术, 2022, 45(11): 120-125.
- [10] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multi box detector[C]. Tel Aviv: European Conference on Computer Vision, 2016.
- [11] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [12] KISANTAL M, WOJNA Z, MURAWSKI J, et al. Augmentation for small object detection[J]. ArXiv preprint arXiv:1902.07296, 2019.
- [13] 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): 1953-1959.
- [14] XU W, WAN Y. ELA: Efficient local attention for deep convolutional neural networks[J]. Arxiv preprint arXiv: 2403.01123, 2024.
- [15] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]. Salt Lake City: IEEE Conference on Computer Vision and Pattern Recognition, 2018.
- [16] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]. Tel Aviv: European Conference on Computer Vision, 2018.
- [17] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design[C]. Vancouver, BC: IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021.
- [18] 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, 2015, 39(6): 1137-1149.
- [19] WEI S, SU H, MING J, et al. Precise and robust ship detection for high-resolution SAR imagery based on HR-SDNet[J]. Remote Sensing, 2020, 12(1): 167-196.

作者简介

李波, 博士, 教授, 主要研究方向为智能信息处理。

E-mail: leebo@yeah.net

李志康(通信作者), 硕士研究生, 主要研究方向为深度学习和图像信息处理。

E-main: 2364929570@qq.com

周钰彬, 硕士研究生, 主要研究方向为智能信息处理。

E-mail: 1141079528@qq.com