

# 基于 CAM-YOLOX 的大场景 SAR 图像 近岸场景舰船目标检测<sup>\*</sup>

张慧敏 李 锋 黄炜嘉 彭珊珊

(江苏科技大学海洋学院 镇江 212100)

**摘 要:** 针对大场景 SAR 图像近岸场景舰船目标检测中遇到的陆地目标虚警和岸边目标漏检等问题,基于 YOLOX 设计了一种轻量化的改进模型 CAM-YOLOX。首先,在骨干部分嵌入 CAM,增强舰船特征提取以保持较高的检测性能;其次,在特征金字塔网络结构中增加一个浅层分支,以增强对小目标特征的提取能力;最后,在特征融合网络中用 Shuffle unit 替换 CSPLayer 中的 CBS 和堆叠的 Bottleneck 结构,实现了模型压缩。在 LS-SSDD-v1.0 遥感数据集上进行实验,实验结果表明,本文改进算法相较于原始算法在近岸场景舰船检测的精确率 P 提高了 5.51%,召回率 R 提高了 3.68%,模型参数量减小了 16.33%。本文算法能在不增加模型参数量的情况下,有效抑制近岸场景中陆地上的虚警和减少岸边舰船漏检率。

**关键词:** 近岸场景;SAR 图像;舰船检测;注意力机制;Shuffle unit

**中图分类号:** TP751 **文献标识码:** A **国家标准学科分类代码:** 510.4

## Near-shore ship target detection in large scene SAR images based on CAM-YOLOX

Zhang Huimin Li Feng Huang Weijia Peng Shanshan

(Ocean College, Jiangsu University of Science and Technology, Zhenjiang 212100, China)

**Abstract:** A lightweight improved model CAM-YOLOX is designed based on YOLOX to address the issues of false alarms of land targets and missed detections of shore targets encountered in ship target detection in large scene Synthetic Aperture Radar(SAR)images in near-shore scenes. Firstly, embed Coordinate Attention Mechanism in the backbone to enhance ship feature extraction and maintain high detection performance; Secondly, add a shallow branch to the Feature Pyramid Network structure to enhance the ability to extract small target features; Finally, in the feature fusion network, Shuffle unit was used to replace CBS and stacked Bottleneck structures in CSPLayer, achieving model compression. Experiments are carried out on the LS-SSDD-v1.0 remote sensing dataset. The experimental results show that compared with the original algorithm, the improved algorithm in this paper has the precision increased by 5.51%, the recall increased by 3.68%, and the number of model parameters decreased by 16.33% in the near-shore scene ship detection. The proposed algorithm can effectively suppress false alarms on land and reduce the missed detection rate of ships on shore without increasing the number of model parameters.

**Keywords:** near-shore scene;SAR image;ship detection;attention mechanism;Shuffle unit

## 0 引 言

合成孔径雷达(synthetic aperture radar, SAR)是一种主动式微波成像雷达,具有分辨率高、抗云雾干扰、全天候成像的能力,在环境监测、沉船救助、漏油检测、海上航运控制等领域有着重要应用<sup>[1]</sup>。SAR 图像中的舰船检测研究

在军用和商务使用上都有着重要性。目前,关于 SAR 图像中远海情景舰船的检测研究已获得了重要的发展,不过关于近岸舰船的检测研究(近岸场景通常表现出较差的性能,因为在近岸场景中有许多干扰)则相对较少。

近岸场景舰船检测的困难主要包括 SAR 图像固有的散斑噪声和陆地上散射强度强的干扰物等。针对以上问

题,近年来,研究人员逐步对基于深度学习的 SAR 图像近岸场景舰船目标检测方法进行探索。Hao 等<sup>[2]</sup>提出了一种基于双向注意力特征金字塔网络的近岸场景舰船检测方法,在金字塔的每个特征图上连接一个卷积块注意力模块并且在原始金字塔结构后面拼接一个自底向上的金字塔结构,改善背景的干扰提高检测性能。Zhe 等<sup>[3]</sup>提出了一种新的基于多模态显著性的近岸舰船检测方法,建立并组合了 4 个显著图,用于具有相似港口设施的复杂近岸场景 SAR 图像中的舰船检测。Cheng 等<sup>[4]</sup>为了提高近岸舰船的检测性能提出了一种基于各向异性金字塔差异的显著性增强算法,通过双边滤波器构造 SAR 图像的各向异性金字塔,并且利用最细两个尺度和最粗两个尺度之间的差异生成显著图,可以有效地提高检测精度。Tian 等<sup>[5]</sup>为了实现精确定位和抑制虚警,提出了一种集成多尺度特征融合网络、旋转区域建议网络和上下文池化的框架。Shun 等<sup>[6]</sup>采用了一种新颖的高分辨率特征金字塔网络构建了 HR-SDNet,充分利用了高分辨率和低分辨率卷积的特征图。龚声蓉等<sup>[7]</sup>为了有效降低 SAR 图像近岸场景中舰船的虚警和漏检情况,设计了基于可变形空洞卷积的骨干网络。富强等<sup>[8]</sup>结合了注意力机制和 CSL 算法改进了 YOLOv5 网络,改善了近岸场景舰船的检测性能。李永刚等<sup>[9]</sup>构建了 DFF-YOLOv5 算法,该算法利用级联和并列金字塔以及空洞卷积进行改进,有效地提高了复杂背景近岸舰船的检测性能。

然而,在大场景 SAR 图像中,以上近岸舰船检测方法往往容易出现大量的陆地虚警和岸边目标漏检现象。主要原因可能是:首先,由于大部分区域为陆地背景,舰船目标所占比例较小,逐像素检测容易产生虚警<sup>[10]</sup>;其次,在岸边舰船密集停靠时可能会漏检一些目标。针对大场景 SAR 图像近岸场景目标检测的这些问题,本文改进了基于 YOLOX 的轻量化目标检测网络,称之为 CAM-YOLOX。包括在骨干部分嵌入坐标注意力机制(coordinate attention mechanism, CAM)以增强特征表达能力;将具有大量位置信息的浅层特征层与深层特征层融合,并增加解耦头以进行小目标检测;在特征融合网络中优化 CSPLayer 结构,以降低模型的参数量。在不增加模型参数量的情况下,改进后的算法能有效抑制近岸场景中陆地上的虚警和减少岸边舰船漏检率,为深度学习在大场景 SAR 图像舰船目标检测领域的应用提供了一定的研究基础。

## 1 方 法

### 1.1 YOLOX-s 算法基本原理

YOLOX<sup>[11]</sup>是在 YOLOv3 基础上改进的目标检测网络系列算法,它包括 S、M、L 和 X 不同规模的网络,以及 Tiny 和 Nano 系列。其中 YOLOX-s 具有结构简单、参数较少、便于部署的特点,本文将其作为基准模型。YOLOX-s 一般由输入层、骨干网络、特征融合网络和检测头构成。网

络输入层,对输入到网络的图片进行 Mosaic 和 Mixup 数据增强。骨干特征提取网络由 CSPDarknet<sup>[12]</sup> 构成,并使用全卷积层来防止池化过程中浅层特征的丢失。特征融合网络结构采用了与 YOLOv4 相同的路径聚合网络(path aggregation network, PANet)结构<sup>[13]</sup>,通过对特征进行上采样和下采样,实现了特征融合。检测头采用 YOLOHead 对提取的特征进行解耦,使回归与分类分成两个部分。最后在预测端将不同尺度的特征向量进行融合,通过 SimOTA 方法对融合的特征向量进行正样本筛选匹配,得到与真实样本近似的预测候选框<sup>[14]</sup>。

### 1.2 CAM-YOLOX 算法

为进一步降低大场景 SAR 图像中近岸场景舰船目标检测的虚警和漏检,本文在特征提取、改进特征金字塔网络(feature pyramid network, FPN)结构和压缩模型方面进行改进,形成 CAM-YOLOX 的网络结构如图 1 所示。首先,在骨干网络中加入坐标注意力机制 CAM,以增强舰船特征提取并且减少海岸、码头、岛礁等背景信息的干扰;其次,改进特征融合网络,在 FPN 结构中增加一个浅层分支,以增强对舰船小目标的特征提取能力;最后,在特征融合网络中用 Shuffle unit 替换原网络中的 CBS 和堆叠的 Bottleneck 结构,实现模型压缩。

#### 1) 基于 CAM 的骨干网络的改进

SAR 图像中舰船目标容易受到海岸、码头、岛礁等场景的干扰,不能很好地提取舰船目标的细节信息,从而造成漏检错检等问题。注意力机制可以使网络模型聚焦在感兴趣的局部信息中,使网络更加关注目标特征,从而提高对近岸目标的检测准确率。在骨干网络中引入注意力机制,使网络能够自适应地注意舰船目标,提高检测精度。

目前主流注意力机制模块有通道注意力机制(squeeze-and-excitation networks, SE)<sup>[15]</sup>、卷积注意力机制(convolutional block attention module, CBAM)<sup>[16]</sup>、CAM 注意力机制<sup>[17]</sup>等。SE 只考虑通道信息而忽略了位置信息,位置信息对于检测舰船小目标尤为重要<sup>[18]</sup>。CBAM 虽然考虑了位置信息,但具有较高的计算复杂度,需要更多的计算资源。CAM 作为通道域的最新进展,灵活且轻量级,可以立即并入网络。它通过分别在水平和垂直方向上对特征图进行平均池化来实现通道编码,以加权的方式将空间信息融合到信道中。通过捕获跨通道信息和位置信息解决了上述注意力机制的缺点,使感兴趣的目標在特征映射上更加可见。CAM 的结构如图 2 所示。

图 2 中,  $C$ 、 $H$ 、 $W$  分别是输入特征图的宽、高和通道数,  $r$  是下采样比例。首先,每个通道都使用  $(H, 1)$  和  $(1, W)$  的池化核来沿水平和垂直方向进行平均池化。其输出的高度和宽度分别可以表示为:

$$\mathbf{Z}_c^h(h) = \frac{1}{W} \sum_{0 \leq i < W} X_c(h, i) \quad (1)$$

$$\mathbf{Z}_c^w(w) = \frac{1}{H} \sum_{0 \leq j < H} X_c(j, w) \quad (2)$$

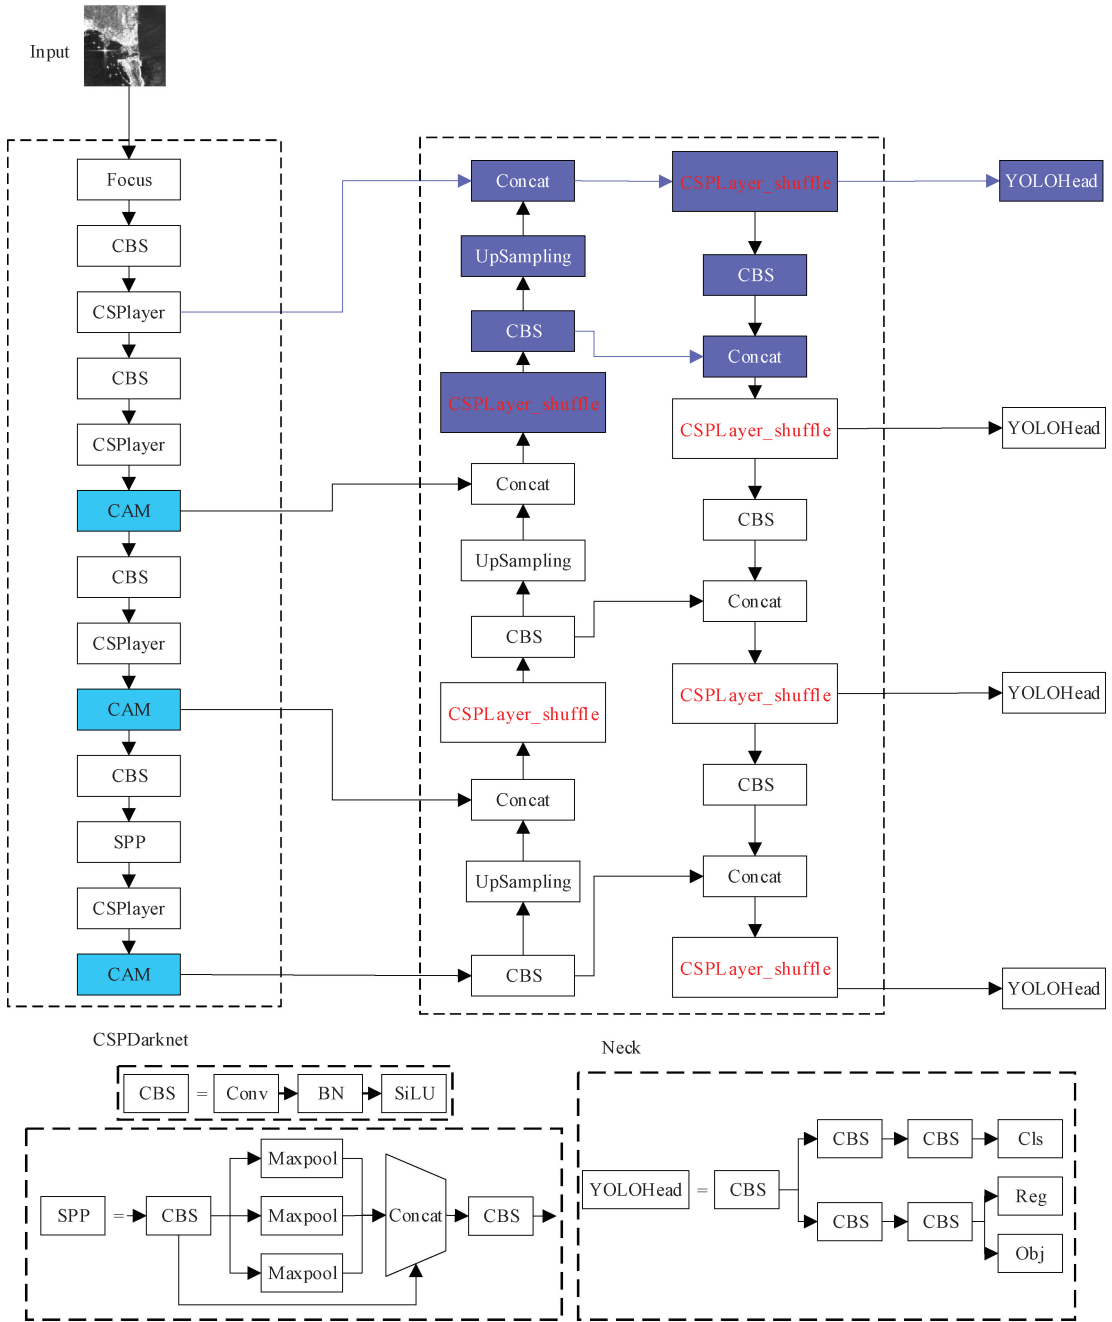


图 1 CAM-YOLOX 的网络结构

式(1)、(2)中,  $h$  和  $w$  是与当前注意力模块相对应的输入特征图的高度和宽度,  $Z_c^h(h)$  表示高度为  $h$  的第  $c$  个通道的输出,  $Z_c^w(w)$  表示宽度为  $w$  的第  $c$  个通道的输出, 即  $Z_c^h(h)$  和  $Z_c^w(w)$  分别表示水平方向和垂直方向位置信息聚合后的输出值。

然后, 对所获得的输出进行维度层面的拼接, 将拼接的张量进行特征提取, 如式(3)所示。

$$f = \delta(F_1[\mathbf{z}^h, \mathbf{z}^w]) \quad (3)$$

式中:  $\mathbf{z}^h$ 、 $\mathbf{z}^w$  分别为沿着水平和垂直方向聚合的特征,  $[\mathbf{z}^h, \mathbf{z}^w]$  为将水平和垂直方向的张量在相同维度拼接的结果。

果,  $F_1$  为卷积操作,  $\delta$  为非线性激活函数。

接着, 沿着空间维度将中间特征图  $f$  分成  $f^h$  和  $f^w$  两个单独的张量, 使用  $F^h$  和  $F^w$  两个一维卷积将  $f^h$  和  $f^w$  变为与输入相同通道数的张量, 如式(4)、(5)所示。

$$\mathbf{g}^h = \sigma(F_h(f^h)) \quad (4)$$

$$\mathbf{g}^w = \sigma(F_w(f^w)) \quad (5)$$

式中:  $\sigma$  为非线性激活函数。

最后, 扩展  $\mathbf{g}^h$ 、 $\mathbf{g}^w$  用作注意力权值。坐标注意力的最终输出如式(6)所示。

$$y_c(i, j) = x_c(i, j) \times g_c^h(i) \times g_c^w(j) \quad (6)$$

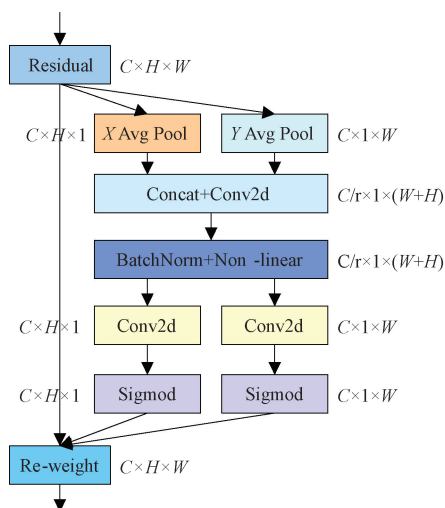


图 2 CAM 的结构图

式(6)中,  $x_c(i, j)$  为原特征层特征,  $y_c(i, j)$  为注意力值对原特征层进行加权分配后的特征层。

## 2) 多尺度特征融合网络的改进

原有骨干网络输出的特征图尺度为  $80 \times 80$ 、 $40 \times 40$ 、 $20 \times 20$ , 可以较好地检测出较大的目标。但是大场景 SAR 图像中舰船目标偏小, 为了提升模型对于近岸场景中小目标的检测效果, 将特征融合网络进行改进, 改进后的多尺度特征融合网络的细化图如图 3 所示。将骨干网络中  $160 \times 160$  的浅层特征层提取并在特征融合网络中进行特征融合, 并在检测层中将原来 3 个解耦头增加至 4 个解耦头, 新增加的解耦头输入特征层大小为  $160 \times 160$ , 复杂近岸场景中的小目标可以更好地与该解耦头的感受野相配, 从而避免因感受野过大导致小目标漏检的问题, 可以让模型对于图像中的小目标有着更好的检测性能。

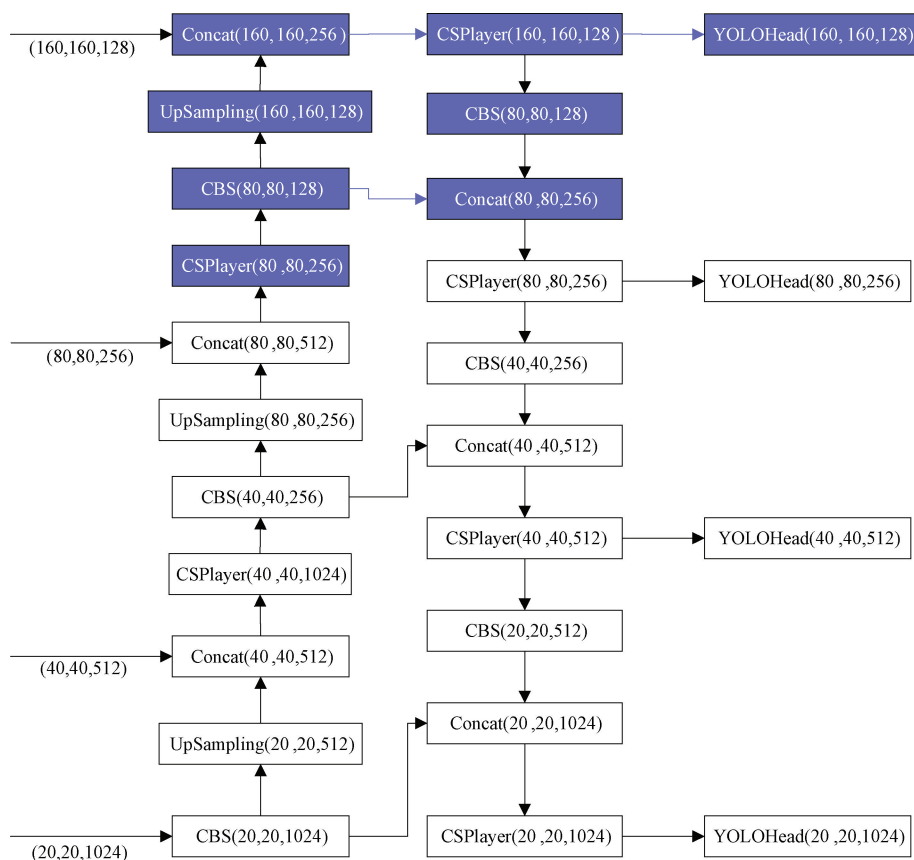


图 3 多尺度特征融合网络的细化

## 3) 特征融合网络的轻量化改进

针对舰船目标的特征提取能力不足提出的改进方法在增强特征提取能力的同时增大了模型参数量。为使模型更加轻量高效, 使用轻量化模块 Shuffle unit 对特征融合网络进行改进, 实现降低模型参数数量的目的。

Shuffle unit<sup>[19]</sup> 结构如图 4 所示。首先, 将输入特征映射的通道划分为两个组, 其中一个组不作处理, 在另一个组中

有两个  $1 \times 1$  的卷积层和一个  $3 \times 3$  的深度可分离卷积层, 这两个组直接连接到 Concat。模型在不增加计算量的前提下, 保证了不同组的舰船特征图在分组卷积之后能够实现特征信息通信。使用轻量化模块 Shuffle unit 替换特征融合网络 CSPlayer 中的 CBS 和堆叠的 Bottleneck 结构, 改进前后的 CSPlayer 结构如图 5 所示。改进后参数量得到压缩, 可以更高效地应用于大场景 SAR 图像的实时检测。








图 4 Shuffle unit 结构



(a) CSPLayer 结构图



(b) CSPLayer\_shuffle 结构图

图 5 CSPLayer 改进前后的对比图

2 实验结果与分析

2.1 实验平台与参数设置

本文在由中国移动研发的云平台“九天·毕昇”上完成了试验,处理器为 Intel(R) Xeon(R) Gold6240CPU@2.60 GHz,显卡为 NVIDIA Tesla V100-PCIE,显存为 32 GB,操作系统为 Ubuntu18.04,开发平台为 CUDA10.2+Python3.9.7+Pytorch1.8.0。

训练参数:初始学习率为 0.01,批训练数 Batchsize 设置为 2,设置迭代次数 epoch 为 100。

2.2 实验数据集

LS-SSDD-v1.0<sup>[20]</sup>数据集由干涉宽幅模式下的 Sentinel-1 来构建,包括海域、港口、海峡和航道等区域。这个数据集的具体信息如表 1 所示。

在 LS-SSDD-v1.0 数据集中,将原始的 15 幅 24 000×16 000 像素的大场景 SAR 图像切割成 9 000 个子图像,每个子图像具有 800×800 像素,其中第 1~第 10 个场景的 6 000 幅子图像被用作训练集,第 11~第 15 个场景的 3 000 个子图像被用作测试集,并且测试集被划分为 766 幅近岸场景测试子集和 2 234 幅远海场景测试子集。在检测中,一幅大场景 SAR 图像的检测结果是由来自同一场景的 600 幅子图像的检测结果拼接而成。数据集的标签格式为 PASCAL VOC,实例类别为舰船。LS-SSDD-v1.0 数据集保留了纯背景图像,因此检测模型可以更有效地学习纯背景特征,减少误报。

2.3 评价指标

实验时采用精确度(precision,P)、召回率(recall,R)、F1 分数和平均精度均值(mean average precision,mAP)对模型进行评估。计算公式如式(7)~(10)所示。

表 1 关于 LS-SSDD-v1.0 数据集的信息

| 参数           | LS-SSDD-v1.0 |
|--------------|--------------|
| 分辨率/m        | 5×20         |
| 子图像数         | 9 000        |
| 近岸场景图像数      | 766          |
| 远海场景图像数      | 2 234        |
| 舰船数          | 6 015        |
| 子图像大小/pixels | 800×800      |
| 小型           | 6 003        |
| 中型           | 12           |
| 大型           | 0            |

$$Precision = \frac{TP}{TP + FP} \quad (7)$$

$$Recall = \frac{TP}{TP + FN} \quad (8)$$

$$F1 = \frac{2P \times R}{P + R} \quad (9)$$

$$mAP = \int_0^1 P(R) dR \quad (10)$$

其中,TP(true positive)表示检测正确且检测样本为真的个数,FP(false positive)表示检测错误且检测样本为真的个数,FN(false negative)则表示检测出错且检测样本为假的数量。

2.4 实验结果及分析

1)消融实验

消融实验设计如表 2 所示。“√”代表添加此模块,方案 0 是原始 YOLOX 网络,方案 1 是引入了 CAM 注意力机制,方案 2 在方案 1 的基础上改进了 FPN 结构,方案 3 在方案 2 的基础上引进了改进的 CSPLayer\_shuffle 结构,是本文提出的最终模型。消融实验的具体结果如表 3 所示。

表 2 消融实验设计

| 方案 | CAM | 改进 FPN | CSPLayer_shuffle |
|----|-----|--------|------------------|
| 0  |     |        |                  |
| 1  | √   |        |                  |
| 2  | √   | √      |                  |
| 3  | √   | √      | √                |

从表 3 中可以看出,对于近岸场景来说,相比于原始网络,方案 1 引入了 CAM 模块,精确率 P 提高了 3.78%,mAP 和召回率 R 都有所提高,说明引入 CAM 模块突出关键特征降低了陆上干扰对舰船检测的影响,抑制虚警率。方案 2 在方案 1 的基础上改进了 FPN 结构,各项指标都有提高,其中召回率 R 提升了 1.58%,降低了漏检率,说明在 FPN 结构中增加一个浅层分支,增强了对舰船小目标特征的提取能力。方案 3 在方案 2 的基础上引入 Shuffle unit

表 3 消融实验结果对比

%

| 模型   | 近岸场景         |              |              |              | 远海场景         |              |              |              | 全部场景         | Params/M    |
|------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|-------------|
|      | P            | R            | mAP          | F1           | P            | R            | mAP          | F1           | mAP          |             |
| 方案 0 | 57.42        | 42.24        | 46.57        | 48.67        | <b>91.81</b> | 83.21        | 87.18        | 87.30        | 73.32        | 8.94        |
| 方案 1 | 61.20        | 43.83        | 47.45        | 51.08        | 90.84        | 83.61        | 87.08        | 87.18        | 73.65        | 8.97        |
| 方案 2 | 62.27        | 45.41        | 47.86        | 52.52        | 90.47        | 85.02        | 87.30        | 87.44        | 73.86        | 9.71        |
| 方案 3 | <b>62.93</b> | <b>45.92</b> | <b>47.96</b> | <b>53.10</b> | 91.42        | <b>85.14</b> | <b>87.67</b> | <b>88.17</b> | <b>74.18</b> | <b>7.48</b> |

对特征融合网络进行轻量化处理,形成最终的改进模型 CAM-YOLOX,模型参数量大幅减小,节约了计算资源且仍可保证对舰船目标的高精度检测。本文改进的 CAM-YOLOX 与原始网络相比,精确率 P 提高了 5.51%,召回率 R 提高了 3.68%,模型参数量减小了 16.33%,并且 mAP 也有所提高,说明改进模型 CAM-YOLOX 在近岸区域的检测性能相较于原始算法能够有效抑制虚警,降低漏检率,提高平均精度均值 mAP,减轻计算压力。

从表 3 中可以看出对于远海场景来说,CAM-YOLOX 相较于改进前的算法,召回率 R 和 mAP 都有提升。虽然 P 有轻微降低,漏检概率产生了一定的负面影响,但是 F1 有所提升,实现了虚警和漏检之间的良好平衡。


如图 6 所示,显示了改进前与改进后方法在 LS-SSDD-v1.0 数据集上的可视化检测结果。展示了图像大小为 24 000×16 000 的大场景测试图像,该图像是通过拼接 600 个 800×800 的子图像生成的。

选择原始尺寸图像中具有代表性的部分进行放大并且比较了改进前后舰船目标的检测效果,将放大部分中检测舰船的部分进一步放大以便于更好的比较检测精度的大小。由图 6(a)YOLOX 网络的检测结果可以看出,陆地上出现了由强散射亮点造成的虚警和岸边区域出现了漏检。由图 6(b)CAM-YOLOX 的检测结果可知,在陆地上出现的虚警被有效地抑制,近岸区域的漏检也大大减少。从放大区域的对比也可以看出,远海区域的舰船检测置信度提高。因此,根据以上对比结果可知,本文改进的方法可以有效地抑制陆地上存在的强散射亮点的虚警并且可以降低近岸区域的漏检率。


2)各模型对比实验

为了验证改进模型 CAM-YOLOX 的有效性,比较了 Faster R-CNN、EfficientDet、SSD-300、YOLOv7、YOLOX 和本文改进模型在 LS-SSDD-v1.0 数据集上的检测性能。Faster R-CNN 和 EfficientDet 是典型的两阶段检测模型,SSD-300、YOLOv7 和 YOLOX 是目前主流的单阶段检测模型。不同算法检测结果对比如表 4 所示。

在近岸场景中,相较于其他方法 CAM-YOLOX 获得了较高的检测性能,62.27%的最佳精确率 P 和 45.41%的最佳召回率 R,并且 mAP 值也达到 47.96%,EfficientDet 较低的 P 意味着检测结果存在较多的虚警,SSD-300 的 R 仅有 6.68%,意味着检测结果存在较多的漏检。在远海场



(a) YOLOX 的检测结果



(b) CAM-YOLOX 的检测结果

图 6 大场景 SAR 图像的舰船检测结果和部分放大

景中,CAM-YOLOX 的 mAP 值最佳。与 Faster R-CNN 相比,本文提出的方法在召回率 R 上有所降低,但 mAP 高于所对比的方法,并且反映虚警和漏检之间平衡的 F1 指

表 4 不同算法性能结果对比

%

| 模型                           | 近岸场景         |              |              | 远海场景         |              |              |              | 全部场景         | Params/M    |
|------------------------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|-------------|
|                              | P            | R            | mAP          | P            | R            | mAP          | F1           | mAP          |             |
| Faster R-CNN <sup>[21]</sup> | 49.14        | 29.11        | 25.27        | 81.55        | <b>87.49</b> | 84.62        | 84.42        | 63.00        | 41.35       |
| SSD-300 <sup>[21]</sup>      | 60.82        | 6.68         | 4.92         | 88.97        | 41.00        | 37.69        | 56.13        | 25.37        | 23.75       |
| EfficientDet <sup>[22]</sup> | 37.62        | 39.75        | 30.48        | 76.00        | 83.88        | 80.37        | 79.75        | 61.35        | 39.40       |
| YOLOv7 <sup>[22]</sup>       | 49.8         | 33.7         | 31.0         | 85.5         | 81.6         | 85.7         | 83.5         | 66.8         | 34.79       |
| YOLOX                        | 57.42        | 43.83        | 46.57        | <b>91.81</b> | 83.21        | 87.18        | 87.30        | 73.32        | 8.94        |
| CAM-YOLOX                    | <b>62.27</b> | <b>45.41</b> | <b>47.96</b> | 90.01        | 85.02        | <b>87.30</b> | <b>87.44</b> | <b>73.86</b> | <b>7.48</b> |

标上升幅度达 3.02%，实现了良好平衡。综上所述，与其他方法相比，CAM-YOLOX 的检测优势更为突出在近岸场景舰船检测上，且模型最轻量。

3 结 论

本文基于 YOLOX-s 提出了一种大场景 SAR 图像舰船目标检测算法 CAM-YOLOX。该算法专注于解决近岸场景下舰船目标检测所面临的一些问题。在骨干网络中嵌入了坐标注意力机制 CAM，以增强模型的特征表达能力，突出重要特征，从而保持较高的检测性能；对 FPN 结构进行了改进，在颈部层引入了主干特征提取网络中的 160×160 的浅层特征层进行融合，并添加了一个额外的检测头；采用 Shuffle unit 简化特征融合网络中的 CSPLayer 结构。该方法能够有效地检测近岸场景下的舰船，有效抑制由陆地上产生的虚警和减小岸边场景下舰船漏检的情况，并且可以使模型更加轻量化。尽管改进的算法在近岸场景检测上的精确率 P 和召回率 R 方面取得了一定的提高，但在远海场景的检测上精确率 P 有轻微降低，漏检概率产生了一定的负面影响。因此，下一步的研究将主要集中在进一步改善这一问题。

参考文献

[1] 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.

[2] HAO G, DONG B G. Closely arranged inshore ship detection using a bi-directional attention feature pyramid network[J]. International Journal of Remote Sensing, 2023, 44(22): 7106-7125.

[3] CHEN Z, DING Z, ZHANG X, et al. Inshore ship detection based on Multi-Modality saliency for synthetic aperture radar images[J]. Remote Sensing, 2023, 15(15): 3868.

[4] JIANDA C, DELIANG X, JIAXIN T, et al. Inshore ship detection in large-scale SAR images based on saliency enhancement and bhattacharyya-like distance[J]. Remote

Sensing, 2022, 14(12): 2832.

[5] TIAN T, PAN Z, TAN X, et al. Arbitrary-oriented inshore ship detection based on multi-scale feature fusion and contextual pooling on rotation region proposals [J]. Remote Sensing, 2020, 12 ( 2 ): 339-339.

[6] 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): 167-167.

[7] 龚声蓉, 徐少杰, 周立凡, 等. 融入混合注意力的可变形空洞卷积近岸 SAR 小舰船检测[J]. 中国图象图形学报, 2022, 27(12): 3663-3676.

[8] 富强, 杨威, 陈杰. 基于 YOLOv5 的近岸 SAR 舰船目标检测方法[J]. 上海航天(中英文), 2022, 39(3): 67-76, 90.

[9] 李永刚, 朱卫纲, 黄琼男, 等. 复杂背景下 SAR 图像近岸舰船目标检测[J]. 系统工程与电子技术, 2022, 44(10): 3096-3103.

[10] 张天文, 张晓玲. 一种大场景 SAR 图像中舰船检测虚警抑制方法[J]. 现代雷达, 2022, 44(2): 1-8.

[11] GE Z, LIU S, WANG F, et al. YoloX: Exceeding yolo series in 2021[J]. ArXiv Preprint, 2021, Arxiv: 2107. 08430.

[12] WANG C, LIAO H, WU Y, et al. CSPNet: A new backbone that can enhance learning capability of CNN[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, 2020: 390-391.

[13] LIU S, QI L, QIN H, et al. Path aggregation network for instance segmentation[C]. Conference on Computer Vision and Pattern Recognition (CVPR) MIEEE, 2018: 8759-8768.

[14] 刘霖, 肖嘉荣, 王晓蓓, 等. 改进 YOLOX 的 SAR 近

岸区域船只检测方法[J]. 电子科技大学学报, 2023, 52(1): 44-53.

[15] 叶彦斐, 程立, 侯翔一. 基于改进 YOLOv5 的钢轨内部伤损 B 显图像识别与分类[J]. 国外电子测量技术, 2023, 42(12): 70-76.

[16] 赵恩玄, 何云勇, 沈宽, 等. 基于深度学习的铸件 CT 图像分割算法[J]. 仪器仪表学报, 2023, 44(11): 176-184.

[17] 程德强, 陈杰, 寇旗旗, 等. 融合层次特征和注意力机制的轻量化矿井图像超分辨率重建方法[J]. 仪器仪表学报, 2022, 43(8): 73-84.

[18] 胡欣, 马丽军. 基于 YOLOv5 的多分支注意力 SAR 图像舰船检测[J]. 电子测量与仪器学报, 2022, 36(8): 141-149.

[19] ZHANG X, ZHOU X, LIN M, et al. Shufflenet: An extremely efficient convolutional neural network for mobile devices [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 6848-6856.

[20] 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.

[21] 张天文. 基于深度学习的 SAR 图像舰船检测及识别技术研究[D]. 成都: 电子科技大学, 2022.

[22] YU N, REN H, DENG T, et al. A lightweight radar ship detection framework with hybrid attentions[J]. Remote Sensing, 2023, 15(11): 2743.

作者简介

张慧敏, 硕士研究生, 主要研究方向为图像信息处理与机器视觉。

E-mail: 1759864026@qq.com

李锋(通信作者), 副教授, 主要研究方向为图像信息处理与机器视觉。

E-mail: Lifengsl@126.com

黄炜嘉, 博士研究生, 讲师, 主要研究方向为生物医学信号检测与处理。

彭珊珊, 硕士研究生, 主要研究方向为图像信息处理与机器视觉。