

DOI:10.3969/j.issn.1672-2337.2024.01.003

# 用于SAR图像舰船目标检测的MAF-Net和CS损失

张丽丽, 蔡健楠, 刘雨轩, 屈乐乐

(沈阳航空航天大学电子信息工程学院, 辽宁沈阳 110136)

**摘要:** 深度学习算法以其端到端训练和高准确率等优势被广泛应用于合成孔径雷达图像舰船检测领域。然而, SAR图像中舰船目标尺寸跨度较大, 且易受到复杂背景和噪声的干扰, 从而影响识别精度。为了进一步提高网络的检测精度, 本文提出了一个多尺度注意力融合网络。该网络主要包含一个多尺度特征注意力融合模块, 该模块使用骨干网络输出的特征图, 融合多尺度的信息, 在空间和通道维度对FPN输出的特征图进行增强, 用于抑制噪声和背景对舰船目标的影响, 提升网络的特征提取能力。此外, 本文还提出了余弦相似损失, 通过计算目标与非目标区域的余弦相似度, 使网络更准确地区分船舶目标与背景, 以进一步提高准确率。大量的实验表明, 在SSDD和SAR-Ship-Dataset数据集上, 本文所提的方法与现有的几种算法相比具有更高的检测精度。

**关键词:** 目标检测; 深度学习; SAR图像; 多尺度注意力融合网络; 余弦相似损失

中图分类号: TN958; TN957.51

文献标志码: A

文章编号: 1672-2337(2024)01-0014-07

**引用格式:** 张丽丽, 蔡健楠, 刘雨轩, 等. 用于SAR图像舰船目标检测的MAF-Net和CS损失[J]. 雷达科学与技术, 2024, 22(1): 14-20.

ZHANG Lili, CAI Jiannan, LIU Yuxuan, et al. A Multi-Scale Attention Fusion Network and Cosine Similar Loss for SAR Ship Detection[J]. Radar Science and Technology, 2024, 22(1): 14-20.

## A Multi-Scale Attention Fusion Network and Cosine Similar Loss for SAR Ship Detection

ZHANG Lili, CAI Jiannan, LIU Yuxuan, QU Lele

(College of Electronic Information Engineering, Shenyang Aerospace University, Shenyang 110136, China)

**Abstract:** Deep learning algorithms are widely used in the field of synthetic aperture radar (SAR) image ship detection for their advantages of end-to-end training and high accuracy. However, ship targets in SAR images span a large size and are susceptible to the interference from complex backgrounds and noise, which affects the detection accuracy. To further improve the detection accuracy of the network, a multi-scale attention fusion network (MAF-Net) is proposed in this paper. The network mainly contains a multi-scale feature attention fusion (MFAF) module, which uses the feature maps output from the backbone network, fuses the multi-scale information, and enhances the feature maps output from the FPN in the spatial and channel dimensions. In this way, the influence of noise and background on the ship target is suppressed and the feature extraction capability of the network is enhanced. In addition, a cosine similar (CS) loss is proposed, which enables the network to more accurately distinguish the ship target from the background by calculating the cosine similarity between the target and non-target regions, to further improve the accuracy. Numerous experiments show that the proposed methods have higher detection accuracy compared with several existing algorithms on SSDD and SAR-Ship-Dataset datasets.

**Key words:** target detection; deep learning; synthetic aperture radar (SAR) image; multi-scale attention fusion network; cosine similar (CS) loss

## 0 引言

合成孔径雷达(Synthetic Aperture Radar, SAR)具有高分辨率、全天时、全天候工作等特点<sup>[1]</sup>, 相比于传统光学传感器, 其在海洋监测等任务中拥有

更大的优势。基于SAR图像的舰船目标检测任务在海上巡逻和监测、海上交通管理、海上搜索和救援等领域中具有重要作用, 在军用和民用领域均有广泛的应用场景<sup>[2]</sup>。

对于传统的SAR舰船检测方法, 恒虚警率

收稿日期: 2023-07-13; 修回日期: 2023-08-17

基金项目: 辽宁省兴辽英才计划项目基金(No.XLYC1907134); 辽宁省教育厅项目(No.LJKZ0174)

(Constant False Alarm Rate, CFAR)<sup>[3-5]</sup>算法由于其较低的算法复杂度而被广泛使用。其原理是估计表面杂波的概率密度函数,并根据预先设定的虚警率自适应地调整检测阈值。然而在近岸场景下,陆地区域的背景较为复杂,这使得杂波建模和阈值设定变得困难,导致检测性能降低。最近,随着深度学习的发展,SAR图像舰船目标检测的准确率得到了进一步的提高。文献[6]提出了一种无锚框的功率变换和特征对齐引导网络(Power Transformation and Feature Alignment-guided Network, Pow-FAN),它包含了用于抑制噪声的PCB(power-based convolution block)模块和用于特征融合的FAB(feature alignment block)模块。为了抑制噪声和复杂背景的影响,文献[7]设计了跨尺度自注意力模块,除此之外,还提出了区域预测感知一对一标签分配以挑选最合适的正负样本。文献[8]基于协调注意模块<sup>[9]</sup>提出了一个CSPMRes2(cross stage partial network with a modified res2net)模块,并将其应用于YOLOv5网络中,取得了较好的效果。文献[10]提出了注意力引导的平衡特征金字塔网络(Attention-guided Balanced Feature Pyramid Network, A-BFPN)并设计了通道注意力引导的融合网络模型,在利用语义和多级互补特征的同时缓解特征图融合过程中的混叠效应。文献[11]为提高对密集目标的检测能力提出了关键点估计模块,并设计通道注意力模块减少噪声对舰船目标的干扰。文献[12]设计一个AFF(adjacent feature fusion)模块减少了由于注意力分散导致的不同尺度特征之间的信息差异,同时将AFF和swin Transformer<sup>[13]</sup>结合提出了ESTD-NET(enhancement Swin transformer detection network),进一步提高检测精度。上述方法都通过注意力模块提高网络的特征提取能力。然而,文献[6, 8, 10-11]的注意力机制较为简单,注意力结果不理想。文献[7]和[12]中使用的基于transformer的注意力机制虽然可以取得较好的效果,但计算量较大。此外,在SAR图像中,斑点噪声、近岸场景下的陆地背景均会影响检测结果,使舰船目标被漏检或者将陆地区域误检为目标。

为了解决上述问题,本文提出了多尺度特征注意力融合网络(Multi-scale Attention Fusion Net-

work, MAF-Net),其包含MFAF(multi-scale feature attention fusion)模块和余弦相似(Cosine Similar, CS)损失。MFAF模块用于对FPN(Feature Pyramid Network)输出的3个不同尺度特征图进行增强,通过融合深层的语义信息,增强了对噪声的抑制效果,从而提高了检测的准确率。CS损失在训练过程中计算目标与非目标区域的余弦距离,并在训练过程中让此距离减小,以增强网络对目标的识别精度。

## 1 MFAF模块

本文基于FCOS(fully convolutional one-stage object detection)<sup>[14]</sup>提出了MAF-Net,其结构如图1所示,该网络包含4个部分:主干网络、MFAF模块、FPN和分类回归子网络。其中MFAF模块对FPN输出的特征图进行增强。并且使用focal损失、CIoU<sup>[15]</sup>损失和CS损失进行训练。

在SAR图像中,舰船目标的长宽比普遍较为极端,且船只朝向不固定。因此在特征图中,舰船目标对应的位置很容易包含较多的背景信息,从而对检测结果造成干扰,影响精度。此外,由于分辨率以及拍摄角度的不同,SAR舰船目标的尺寸跨度较大。单一的特征金字塔网络结构较为简单,不能充分地利用每个尺度的特征中的信息。在近岸场景下,陆地背景复杂,部分岛屿与舰船目标的形状相似,因此会造成误检,同时部分舰船目标离陆地较近且排列密集,易受到噪声的影响,从而导致漏检。所有这些问题都将导致网络检测性能受到限制。为了解决上述问题,本文提出了MFAF模块。其结构如图2所示。该模块使用不同尺度间的信息对FPN输出的特征图进行增强,以提升网络的特征提取能力,抑制噪声对舰船目标的干扰。 $X_i \in \mathbb{R}^{256 \times H_i \times W_i}$ ,  $i = 3, 4, 5$ 是从FPN输出的特征图,其中 $X_5$ 和 $X_3$ 分别是FPN输出的最深层特征和最浅层特征,通道数为256,  $H_i$ 、 $W_i$ 分别为特征图的高和宽。首先对特征图 $X_5$ 在空间上分别使用最大池化和平均池化操作,随后将结果送入MLP模块以得到 $T_5^{(1)} \in \mathbb{R}^{C_s \times 1 \times 1}$ 和 $T_5^{(2)} \in \mathbb{R}^{C_s \times 1 \times 1}$ 。然后通过 $T_5^{(1)}$ 和 $T_5^{(2)}$ 对特征图 $X_5$ 进行通道维度上的增强。对于其他的特征 $X_i$ ,  $i = 3, 4$ ,先经过空间上的最大池化和平均池化操作,然后将结果与

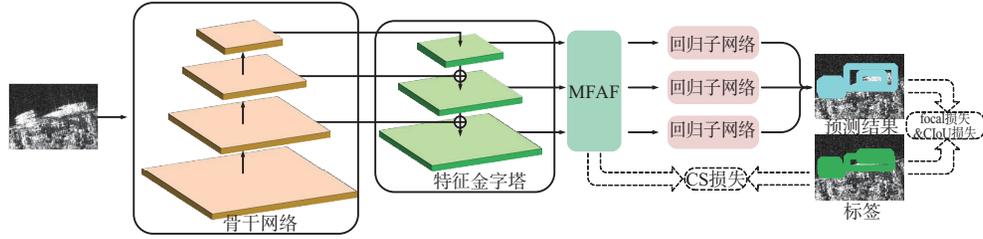


图1 MAF-Net网络结构

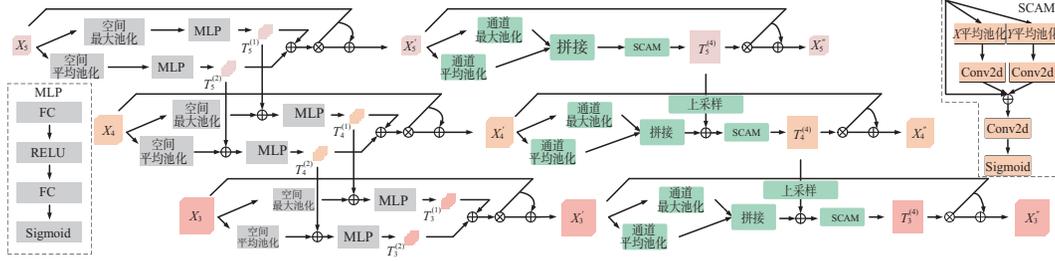


图2 MFAF模块结构

$T_{i+1}^{(1)} \in \mathbb{R}^{C_{i+1} \times 1 \times 1}$  和  $T_{i+1}^{(2)} \in \mathbb{R}^{C_{i+1} \times 1 \times 1}$  分别相加后再送入MLP模块中。其公式可以表示如下:

$$X'_i = BD((T_i^{(1)}) + (T_i^{(2)})) \cdot X_i + X_i \quad (1)$$

$$T_i^{(1)} = \begin{cases} MLP(\text{Max}_{h \in H_i, w \in W_i}(X_{i,h,w})), i=5 \\ MLP(\text{Max}_{h \in H_i, w \in W_i}(X_{i,h,w}) + T_{i+1}^{(1)}), i=3,4 \end{cases} \quad (2)$$

$$T_i^{(2)} = \begin{cases} MLP(\frac{1}{H_i W_i} \sum_{h=1}^{H_i} \sum_{w=1}^{W_i} X_{i,h,w}), i=5 \\ MLP(\frac{1}{H_i W_i} \sum_{h=1}^{H_i} \sum_{w=1}^{W_i} X_{i,h,w} + T_{i+1}^{(2)}), i=3,4 \end{cases} \quad (3)$$

式中,  $X'_i \in \mathbb{R}^{C_i \times H_i \times W_i}$ ,  $i=3,4,5$  为经过通道增强后的特征,  $BD()$  为广播操作,  $\cdot$  表示按元素相乘。

MLP是层数为2的多层感知机。将经过通道增强后的特征图  $X'_i$  在通道维度上分别取最大值和平均值, 随后将结果在通道维度进行拼接得到  $T_5^{(3)} \in \mathbb{R}^{2 \times H_i \times W_i}$ , 然后将  $T_5^{(3)}$  送入SCAM模块以得到  $T_5^{(4)} \in \mathbb{R}^{1 \times H_i \times W_i}$ , 然后使用  $T_5^{(4)}$  对  $X'_i$  进行空间上的增强。对于其他的特征  $X'_i$ ,  $i=3,4$ , 将通道维度的最大值和平均值拼接后, 再分别与  $T_{i+1}^{(3)}$  相加来得到  $T_i^{(3)} \in \mathbb{R}^{2 \times H_i \times W_i}$ ,  $i=3,4$ , 然后再将  $T_i^{(3)}$  送入SCAM模块以得到  $T_i^{(4)}$ 。其公式可以表示如下:

$$X''_i = BD(T_i^{(4)}) \cdot X'_i + X'_i \quad (4)$$

$$T_i^{(3)} = \begin{cases} \text{concate}(\text{Max}_{c \in C_i}(X_{i,c}), \frac{1}{C_i} \sum_{c=1}^{C_i} X_{i,c}), i=5 \\ \text{concate}(\text{Max}_{c \in C_i}(X_{i,c}), \frac{1}{C_i} \sum_{c=1}^{C_i} X_{i,c}) + UP(BD(T_{i+1}^{(4)})), i=3,4 \end{cases} \quad (5)$$

$$T_i^{(4)} = CS(T_i^{(3)}) \quad (6)$$

式中,  $X''_i \in \mathbb{R}^{C_i \times H_i \times W_i}$ ,  $i=3,4,5$  表示经过空间增强后的特征图,  $\text{concate}(A, B)$  表示将  $A$  和  $B$  在通道维度上进行拼接,  $UP$  表示上采样操作。SCAM的结构如图2所示, 首先将  $T_i^{(3)}$  分别在水平方向和垂直方向上做平均池化, 然后将结果通过广播操作变成与  $T_i^{(3)}$  相同的大小, 再分别通过一个卷积层后将结果与输入的  $T_i^{(3)}$  相加, 最后通过输入通道为2, 输出通道为1, 卷积核大小为  $3 \times 3$  的卷积得到  $T_i^{(4)}$ 。公式如下:

$$T_i^{(4)} = CS(T_i^{(3)}) =$$

$$\text{Sigmoid}(F_1^{(3 \times 3)} \otimes (F_2^{(3 \times 3)} \otimes (BD(\frac{1}{H_i} \sum_{h=1}^{H_i} T_{i,h,c}^{(3)}))) +$$

$$F_3^{(3 \times 3)} \otimes (BD(\frac{1}{W_i} \sum_{w=1}^{W_i} T_{i,c,w}^{(3)})) + T_i^{(3)})) \quad (7)$$

式中,  $F_i^{(3 \times 3)}$ ,  $i=1,2,3$  表示大小为  $3 \times 3$  的卷积核参数,  $\otimes$  表示卷积操作。

## 2 CS损失

SAR图像中的陆地背景较为复杂, 且部分船只受噪声影响较大, 因此网络很难有效地区分背景与舰船目标之间的差异, 导致检测结果较差。为了引导网络学习舰船目标与背景之间的差异, 本文提出了CS损失。其目的是使特征图中包含目

标的区域与不包含目标的区域的相似度尽可能的低,从而减少背景与目标的混淆。 $X \in \mathbb{R}^{1 \times H \times W}$ 表示输入的图片。 $X$ 上属于第 $k$ 个目标的标签框内的位置集合可以表示为

$$P_{k,d} = \{(h,w) | ch_k - bh_k + d \leq h \leq ch_k + bh_k - d, \\ cw_k - bw_k + d \leq w \leq cw_k + bw_k - d\} \quad (8)$$

式中: $ch_k, cw_k$ 分别表示第 $k$ 个目标框的中心位置; $bh_k, bw_k$ 表示 $k$ 个目标框的高和宽; $d$ 是用于调整 $P_{k,d}$ 中包含区域的大小。 $P_d = \{p_{1,d}, p_{2,d}, \dots, p_{n,d}\}$ 表示 $X$ 上所有目标框内的位置集合, $n$ 是 $X$ 上目标的个数。

相应地, $X_i'' \in \mathbb{R}^{C_i \times H_i \times W_i}, i = 3, 4, 5$ 上包含在目标框内的位置集合 $\Omega_i$ 和不包含在目标框内的位置集合 $\Gamma_i$ 可以表示为

$$\Omega_i = \{(h,w) | \left(\frac{H}{H_i}\right) \times h, \left(\frac{W}{W_i}\right) \times w \in P_{d_i}\} \\ \Gamma_i = \{(h,w) | \left(\frac{H}{H_i}\right) \times h, \left(\frac{W}{W_i}\right) \times w \in P_{-d_i}\} \quad (9)$$

式中 $d_i$ 表示特征图 $X_i''$ 所对应的理论感受野大小。CS损失的公式如下:

$$L_{\cos} = \frac{1}{3|\Omega_i||\Gamma_i|} \sum_{i=1}^3 \sum_{p \in \Omega_i} \sum_{q \in \Gamma_i} \frac{|\langle X_{i,p}'' , X_{i,q}'' \rangle|}{\|X_{i,p}''\|_2 \|X_{i,q}''\|_2} \quad (10)$$

式中 $|\Omega_i|$ 和 $|\Gamma_i|$ 分别为集合 $\Omega_i$ 和 $\Gamma_i$ 的大小, $\|\cdot\|_2$ 表示向量的二范数, $X_{i,p}'' \in \mathbb{R}^{C_i \times 1 \times 1}$ 表示特征图 $X_i''$ 上位置 $p$ 对应的向量。因此网络的分类损失可以表示为

$$L_{\text{cls}} = L_{\text{focal}} + \alpha L_{\cos} \quad (11)$$

式中 $L_{\text{focal}}$ 为focal损失,超参数 $\alpha$ 用于调整CS损失占比,其被设置为0.5时可以达到最佳结果。

### 3 实验与讨论

#### 3.1 数据集与实验设置

##### 1) 数据集

Official-SSDD (SSDD): SSDD数据集<sup>[16-17]</sup>是SAR船舶检测领域使用最广泛的数据集。于2017年第一次发布,并在2021年发布了更新版。SSDD数据集包含多尺度目标并且背景复杂,大多数图片大小为500像素宽,分辨率从1 m到15 m不等,来自RadarSat-2、TerraSAR-X和Sentinel-1,包含多

种极化方式(HH、VV、VH和HV)。SSDD中船舶的平均尺寸仅为约35×35像素。

SAR-Ship-Dataset: 2019年,Wang等人发布了SAR船舶数据<sup>[18]</sup>。它包含43 819张图像,图像大小为256×256,主要来自Sentinel-1和高分-3。其具有5 m至20 m的分辨率,以及HH、HV、VV和VH极化。与文献[18]中的设置相同,整个数据集被随机分为训练(70%)、验证(20%)和测试数据集(10%)。

##### 2) 实现细节

骨干网络采用ResNet50,并且使用ImageNet数据集对其进行预训练。然后通过COCO数据集对整个网络进行预训练。本文使用15 vCPU Intel(R) Xeon(R) Platinum 8358P CPU @ 2.60GHz, NVIDIA RTX 3090显卡。使用的编程语言是python3.9,深度学习框架为PyTorch1.8.1。GPU计算平台为CUDA 11.1。优化器是初始学习率为0.01的随机梯度下降(SGD)优化器,其学习率在每个衰减步骤被除以10。SSDD和SAR船舶数据集的迭代次数分别为16K和32K。所有的图片尺寸均被缩放为512×512,为了公平地与其他方法进行比较,训练阶段使用的数据增强方法只包括随机翻转以避免过拟合。

#### 3.2 验证评价指标

为了定量地分析所提方法的有效性,本文使用目标检测领域中广泛使用的平均精度(AP)当做验证指标。AP的计算方法如下:

$$AP_d = \int_0^1 P_d(R_d) dR_d \quad (12)$$

式中 $P_d$ 和 $R_d$ 分别为准确率和召回率,其计算方式如下:

$$P_d = \frac{TP_d}{TP_d + FP_d} \\ R_d = \frac{TP_d}{TP_d + FN_d} \quad (13)$$

其中 $d$ 是IoU阈值,对于网络输出的一个样本,其回归框与标签框的IoU大于 $d$ 时,该样本定义为 $TP_d$ ;否则,该样本定义为 $FP_d$ 。对于某一个标签框来说,如果没有网络输出的样本与其IoU大于 $d$ ,则将其定义为 $FN_d$ 。AP为 $d$ 取0.5到0.95时 $AP_d$ 的平

均值:

$$AP = \frac{1}{10} \sum_{n=0}^9 AP_{0.05^n + 0.5} \quad (14)$$

此外,按照目标所占像素区域的大小可以分为大目标(大于 962)、中目标(大于 322 并且小于 962)和小目标(小于 322)。分别计算大、中和小目标的 AP,将所得结果分别定义为 APL、APM 和 APS。

### 3.3 消融实验

为了验证所提出的 MFAF 模块和 CS 损失的有效性,本文以不同的设置在 SSDD 数据集上对 MAF-Net 进行训练。消融实验的结果如表 1 所示。

表 1 在 SSDD 上的消融实验结果

方法	AP	AP <sub>50</sub>	APS	APM	APL	FPS
FCOS	67.4	96.5	67.2	68.8	64.4	36
FCOS+ CS 损失	68.5	97.4	67.7	72.6	66.7	36
FCOS+ MFAF 模块	68.3	97.4	67.5	70.1	65.0	28
FCOS+ MAF-Net	71.2	98.2	67.9	73.4	66.8	28

由于 FCOS 网络的特征提取能力较弱,因此只能达到 96.5% AP<sub>50</sub>,通过添加了 MFAF 模块以后,提升了网络的特征提取能力,针对所有尺度的目标的检测能力均有所提升,使 AP<sub>50</sub>达到了 97.4%。在 FCOS 的训练阶段中添加 CS 损失可以有效地引导网络针对目标与背景之间的差异进行学习,从而提高准确率,可达 97.4% AP<sub>50</sub>。联合使用 MFAF 模块和 CS 损失可以达到最佳的结果,提升了 1.7% AP<sub>50</sub>,可达 98.2% AP<sub>50</sub>。并且在所有尺度上的 AP<sub>50</sub>均可以达到最佳。额外地,通过添加 MFAF 模块后网络的检测速度仅降低了 8%,依旧可以满足对网络的实时性的要求。

为了进一步验证 CS 损失的有效性,并确定最佳的超参数,本文使用占比不同的 CS 损失在 SSDD 数据集上对 FCOS 进行训练,其结果如表 2 所示,其中超参数  $\alpha$  用于调整 CS 损失的占比。当  $\alpha$  为 0 时相当于不添加 CS 损失。其 AP<sub>50</sub> 为最低的 96.5%。通过添加占比不同的 CS 损失后,均能提高 AP<sub>50</sub>,当  $\alpha$  为 0.5 时可以取得最佳的 97.4% AP<sub>50</sub>。

表 2 在 SSDD 上不同参数  $\alpha$  的检测结果

$\alpha$	AP	AP <sub>50</sub>
0	67.4	96.5
0.1	67.7	96.9
0.3	68.0	97.2
0.5	68.5	97.4
0.7	68.2	97.3
0.9	68.1	97.2
1	67.9	97.2

为了直观地展示 MFAF 模块的作用,网络注意力可视化结果如图 3 所示。其中图 3(a)为标签,图 3(b)为仅使用 CBAM 模块的注意力结果,图 3(c)为 MFAF 模块的注意力结果。如图 3(b)中前 4 行所示,当仅用 CBAM 模块时,在近岸场景下,网络注意的位置会受到陆地背景的干扰。而在深海场景下,网络注意的位置不能很好地集中在舰船目标上,注意力较为分散,如图 3(b)中后两行所示。当使用 MFAF 模块时,网络注意的位置受到陆地的干扰较小,并且注意力的结果可以很好地集中在舰船目标上,从而可以取得较好的检测结果。

### 3.4 与其他方法的比较和讨论

本文所提的 MAF-Net 与其他方法的比较如表 3 和表 4 所示,MAF-Net 在 SSDD 和 SAR-Ship-Dataset 中均可以取得最佳的 AP<sub>50</sub>。在 SSDD 数据集上,MAF-Net 可以达到最佳的 98.2% AP<sub>50</sub>,与双阶段和单阶段最佳的 A-BFPN 和 Pow-FAN 相比,分别提高了 1.4% AP<sub>50</sub> 和 1.8% AP<sub>50</sub>。对于 SAR-Ship-Dataset,MAF-Net 达到了最佳的 96.5% AP<sub>50</sub>,与双阶段网络中性能最佳的 ISASDNet+r101 相比,提高了 0.7% AP<sub>50</sub>。与单阶段网络中的 MSSD-Net 相比,提高了 1.4% AP<sub>50</sub>。作为单阶段网络,MAF-Net 不仅在单阶段网络中有最佳的性能,还可以获得比双阶段网络更佳的检测结果。

表 3 SSDD 上的对比实验结果

阶段	方法	AP	AP <sub>50</sub>
双阶段	A-BFPN <sup>[10]</sup>	59.6	96.8
	ESTD-Net <sup>[12]</sup>	59.4	93.8
	ISASDNet+r50 <sup>[19]</sup>	61.0	95.4
	ISASDNet+r101 <sup>[19]</sup>	62.7	96.8
单阶段	Pow-FAN <sup>[6]</sup>	-	96.4
	FCOS+MFAF 模块+CS 损失	71.2	98.2

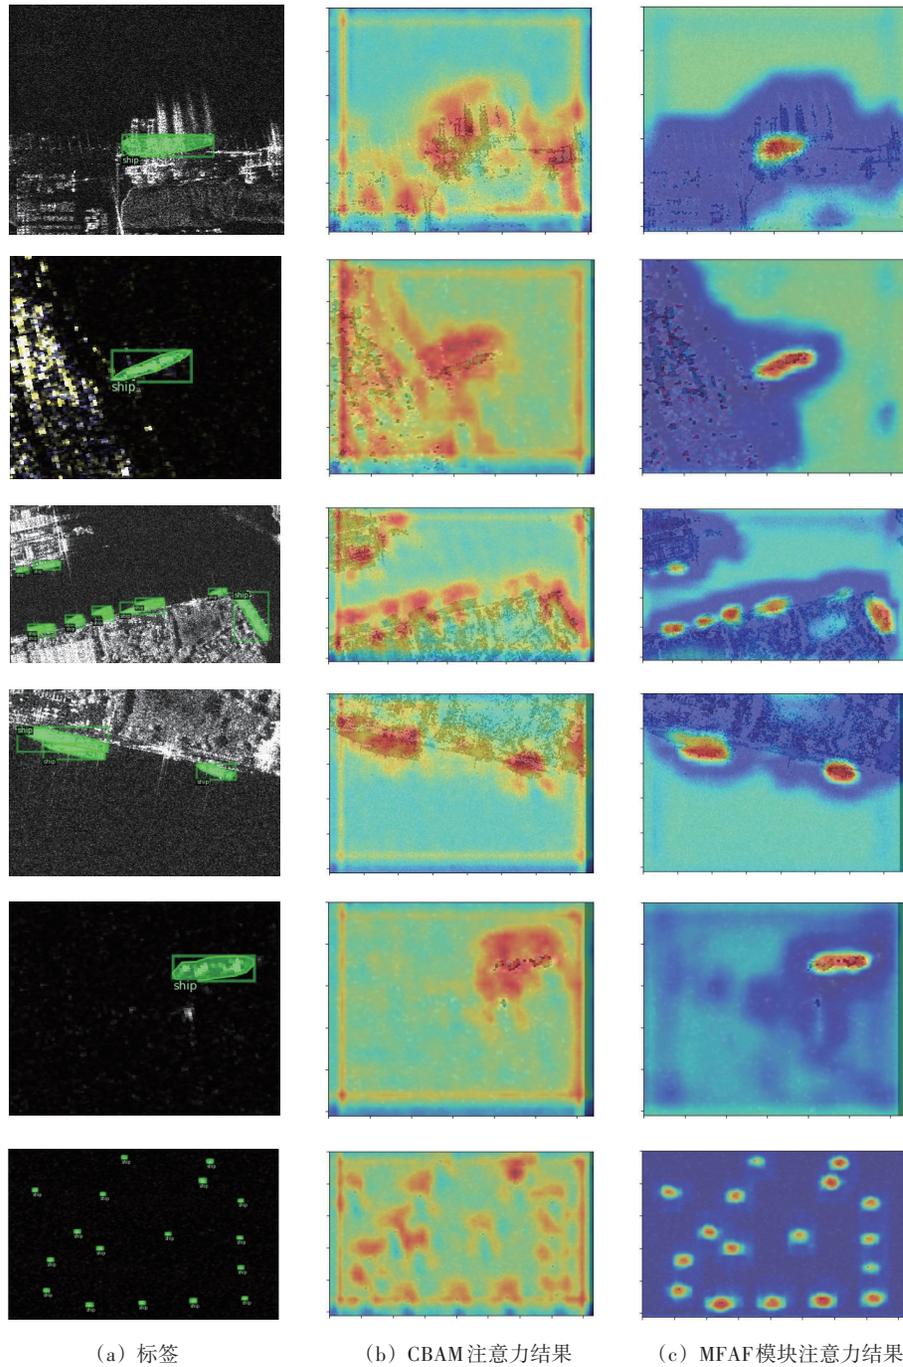


图3 网络注意力结果图

表4 SAR-Ship-Dataset上的对比实验结果

阶段	方法	AP	AP <sub>50</sub>
双阶段	ESTD-Net <sup>[14]</sup>	60.8	95.0
	ISASDNet+r50 <sup>[19]</sup>	60.1	95.3
	ISASDNet+r101 <sup>[19]</sup>	59.6	95.8
单阶段	MSSD-Net <sup>[8]</sup>	60.1	95.1
	FCOS+MFAF模块+CS损失	73.5	96.5

## 4 结束语

为了解决SAR图像中舰船目标检测精度不高的问题。本文提出了一个单阶段无锚框的MAF-Net。其中包含的MFAF模块使用不同尺度特征中的信息对特征进行空间和通道维度的增强,可以有效提升网络的表达能力,抑制背景噪声的干扰,

从而提高网络的检测准确度。此外,本文提出了一个 CS 损失,在训练过程中添加 CS 损失可以使网络更清晰地区分目标与背景之间的差异。通过在两个数据集上的实验表明,MAF-Net 使用的 MFAF 模块和 CS 损失均可以有效地提升检测精度,并且 MAF-Net 与其他方法相比,拥有更佳的准确率。在未来,为了方便模型的部署,可以从模型剪枝的角度出发,在不影响模型准确率的前提下去除网络中冗余的参数,提高网络的运行速度。

### 参考文献:

- [1] 梁恽清,王小华,陈立福.基于深度学习的 SAR 目标检测方法[J].雷达科学与技术,2019,17(5):579-586.
- [2] 夏勇,田西兰,常沛,等.基于深度学习的复杂沙漠背景 SAR 目标检测[J].雷达科学与技术,2019,17(3):305-309.
- [3] DAI Hui, DU Lan, WANG Yan, et al. A Modified CFAR Algorithm Based on Object Proposals for Ship Target Detection in SAR Images[J]. IEEE Geoscience and Remote Sensing Letters, 2016, 13(12):1925-1929.
- [4] LI Mingdian, CUI Xingchao, CHEN Siwei. Adaptive Superpixel-Level CFAR Detector for SAR Inshore Dense Ship Detection[J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19(1):1-5.
- [5] LENG Xiangguang, JI Kefeng, YANG Kai, et al. A Bilateral CFAR Algorithm for Ship Detection in SAR Images[J]. IEEE Geoscience and Remote Sensing Letters, 2015, 12(7):1536-1540.
- [6] XIAO Man, HE Zhi, LI Xinyuan, et al. Power Transformations and Feature Alignment Guided Network for SAR Ship Detection[J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19(1):12-16.
- [7] ZHANG Lili, LIU Yuxuan, HUANG Yufeng, et al. Regional Prediction-Aware Network with Cross-Scale Self-Attention for Ship Detection in SAR Images[J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19(1):36-42.
- [8] ZHOU Kexue, ZHANG Min, WANG Hai, et al. Ship Detection in SAR Images Based on Multi-Scale Feature Extraction and Adaptive Feature Fusion[J]. Remote Sensing, 2022, 14(3):755.
- [9] HOU Qibin, ZHOU Daquan, FENG Jiashi. Coordinate Attention for Efficient Mobile Network Design [C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition, Nashville, TN, USA :IEEE,2021:13708-13717.
- [10] LI Xiuqin, LI Dong, LIU Hongqing, et al. A-BFPN: An Attention-Guided Balanced Feature Pyramid Network for SAR Ship Detection[J]. Remote Sensing, 2022, 14(15):3829.
- [11] MA Xiaorui, HOU Shilong, WANG Yangyang, et al. Multiscale and Dense Ship Detection in SAR Images Based on Key-Point Estimation and Attention Mechanism[J]. IEEE Trans on Geoscience and Remote Sensing, 2022, 60:1-11.
- [12] LI Kuoyang, ZHANG Min, XU Maiping, et al. Ship Detection in SAR Images Based on Feature Enhancement Swin Transformer and Adjacent Feature Fusion[J]. Remote Sensing,2022,14(13):3186.
- [13] LIU Ze, LIN Yutong, CAO Yue, et al. Swin Transformer: Hierarchical Vision Transformer Using Shifted Windows [C]//IEEE/CVF International Conference on Computer Vision, Montreal, QC, Canada: IEEE, 2021:9992-10002.
- [14] TIAN Zhi, SHEN Chunhua, CHEN Hao, et al. FCOS: Fully Convolutional One-Stage Object Detection [C]//IEEE/CVF International Conference on Computer Vision, Seoul, Korea: IEEE, 2019:9626-9635.
- [15] ZHENG Zhaohui, WANG Ping, LIU Wei, et al. Distance-IoU Loss: Faster and Better Learning for Bounding Box Regression [C]//AAAI Conference on Artificial Intelligence, [S.l.]:[s.n.],2019:12993-13000.
- [16] ZHANG Tianwen, ZHANG Xiaoling, LI Jianwei, et al. SAR Ship Detection Dataset (SSDD): Official Release and Comprehensive Data Analysis [J]. Remote Sensing, 2021, 13(8):3690.
- [17] LI Jianwei, QU Changwen, SHAO Jiaqi. Ship Detection in SAR Images Based on an Improved Faster R-CNN [C]//2017 SAR in Big Data Era: Models, Methods, and Applications, Beijing, China:IEEE, 2017:1-6.
- [18] WANG Yuanyuan, WANG Chao, ZHANG Hong, et al. A SAR Dataset of Ship Detection for Deep Learning under Complex Backgrounds [J]. Remote Sensing, 2019, 11(7):765.
- [19] WU Zitong, HOU Biao, REN Bo, et al. A Deep Detection Network Based on Interaction of Instance Segmentation and Object Detection for SAR Images [J]. Remote Sensing, 2021, 13(13):2582.

### 作者简介:

张丽丽 女,博士,副教授,主要研究方向为信号处理、目标识别、图像压缩与 FPGA 系统设计。

蔡健楠 男,硕士研究生,主要研究方向为深度学习与 FPGA 系统设计。

刘雨轩 男,硕士研究生,主要研究方向为深度学习与 FPGA 系统设计。

屈乐乐 男,博士,教授、硕士生导师,主要研究方向为信号处理技术。