

基于特征增强的SAR图像舰船小目标检测算法

严春满[†], 王 铖

(西北师范大学 物理与电子工程学院, 兰州 730070)

摘要: 针对合成孔径雷达(SAR)图像中小目标舰船检测困难的问题,提出基于单次多盒检测器的一种特征增强小目标检测算法. 首先提出一种混合多特征提取模块,采用并行的普通卷积、不同空洞率的空洞卷积以及非对称卷积形成与舰船目标相匹配的感受野,以提高浅层网络对复杂形状小目标的特征提取能力;然后提出一种邻近多特征融合模块,将特征信息进行更科学的深层次融合,对小目标特征进一步增强;最后根据 SAR 图像单通道的特性,缩减特征提取网络 VGG-16 的冗余特征通道. 在公开的 SSDD 数据集上与其他检测算法进行对比实验,实验结果表明,所提出方法将平均精确度提升至 93.44%,检测速度提升至 41.8 FPS,参数量减少为 18.74 M,综合性能优于其他检测算法.

关键词: 合成孔径雷达; 小目标检测; 舰船; 卷积神经网络; 单次多盒检测器; 特征增强

中图分类号: TP751.1

文献标志码: A

DOI: 10.13195/j.kzyjc.2021.0547

引用格式: 严春满,王铖. 基于特征增强的SAR图像舰船小目标检测算法[J]. 控制与决策, 2023, 38(1): 239-247.

A ship small target detection algorithm based on feature enhancement in SAR image

YAN Chun-man[†], WANG Cheng

(College of Physics and Electronic Engineering, Northwest Normal University, Lanzhou 730070, China)

Abstract: To solve the problem of small target ship detection in synthetic aperture radar (SAR) image, a feature enhanced small target detection algorithm based on the single shot multi box detector is proposed. The algorithm proposes a hybrid feature extraction module, which uses general convolution, dilated convolution with different dilation ratio and asymmetric convolution to form a receptive field matching the ship target, so as to improve the feature extraction ability of shallow network for small targets with complex shape. Then, a neighbor feature fusion module is proposed, which integrates the feature information more scientifically and deeply, and further enhances the features of small targets. Finally, according to the characteristics of the single channel of the SAR image, redundant feature channels of the feature extraction network VGG-16 are reduced. It is compared with other detection algorithms on the public SSDD data set. The experimental results show that the proposed method improves the average accuracy to 93.44%, the detection speed is improved to 41.8FPS, and the number of parameters is reduced to 18.74M, which is superior to other detection algorithms in comprehensive performance.

Keywords: synthetic aperture radar; small target detection; ship; convolutional neural network; single shot multibox detector; feature enhancement

0 引言

合成孔径雷达(synthetic aperture radar, SAR)是一种主动式微波成像传感器,由于其成像不受光照、气候等因素影响,可以进行全天时、全天候的监测,在执行遥感监测、导航制导等任务时具有独特的优势^[1]. 我国是一个海洋大国,舰船作为一种重要的军事装备和海洋运输载体需要重点监测. 基于 SAR 图像的舰船目标检测能快速准确地检测各场景下的舰

船目标,在军用和民用领域发挥着越来越关键的作用^[2]. 因此,对 SAR 图像舰船目标检测算法的研究具有重要意义.

传统的 SAR 图像舰船检测算法通常分为 3 个阶段:预处理、候选区域提取和识别. 预处理阶段采用多种图像处理算法将 SAR 图像处理成更易识别的图像. 候选区域提取阶段将可能是舰船的像素提取为候选目标. 识别阶段一般采用人工设计特征训练分

收稿日期: 2021-04-02; 录用日期: 2021-09-28.

基金项目: 国家自然科学基金项目(61961037); 甘肃省教育厅产业支撑计划项目(2021CYZC-30).

[†]通讯作者. E-mail: YanCha02@163.com.

类器,在潜在舰船的区域识别舰船.传统方法的检测效果并不理想,小舰船目标容易受斑点噪声、海杂波等不良因素的影响,难以排除小岛、漂浮冰山等虚警目标,且算法的鲁棒性差、处理步骤繁琐、时间复杂度高.

近年来,基于卷积神经网络(convolutional neural network, CNN)的目标检测技术已经成为主流方式,在自动驾驶、医疗影像等领域^[3]得到广泛应用.基于CNN的目标检测模型主要包括:基于锚框的检测模型(其中包括以R-CNN(region-based CNN)为代表的两阶段检测模型^[4-6]和以YOLO(you only look once)、SSD(single shot multiBox detector)为代表的单阶段检测模型^[7-9])以及以CornerNet等为代表的基于无锚框的检测模型^[10].在当前的光学图像目标检测中,两阶段检测模型检测精度较高,单阶段检测模型检测速度较快.特征金字塔网络(feature pyramid networks, FPN)、BiFPN等特征融合模块^[11-12]出现后,使单阶段检测模型在快速检测的同时保证了检测精度.但是,基于无锚框的检测模型其重叠目标和小目标检测困难的问题没有很好地解决,在实际应用中无法表现出很好的性能.目前基于CNN的目标检测模型与传统目标检测方法相比,在检测精度和鲁棒性上均有了较大的提升.因此,研究人员将深度学习技术广泛应用于SAR图像舰船目标检测任务中.李健伟等^[13]通过特征聚合和优化损失函数等方式改进Faster R-CNN,用于SAR图像舰船目标检测,提高了舰船检测精度.李健伟等^[14]提出了一种级联CNN的Fast R-CNN检测方法,有效降低了舰船检测的虚警率.由于SAR图像舰船目标存在尺寸差异大、小目标多和特征信息少等问题,Wang等^[15]将SSD与FPN相结合,显著提升了SAR图像舰船的检测精度.韩子硕等^[16]在FPN基础上提出超密集FPN,增强舰船特征的融合和重用,提高了小目标在内的多尺度检测能力.

基于CNN的目标检测算法目前已取得较好的成果,但依然存在较多的漏检和误检情况,原因如下:1) SAR图像中舰船目标本身相比光学图像包含较少的特征信息,且由于SAR成像机制导致小目标易受相干斑点噪声影响,运动目标存在拖影、阴影等扰乱目标特征的现象.另外,舰船尺寸变化较大,而基于自然场景的目标检测模型的感受野较为单一,特征信息提取能力较差.2) 在SAR图像中存在较多的小尺寸舰船,虽然FPN等特征融合方式是解决目标多尺度检测的有效方式,但在深层特征中,小目标的语义

特征信息已经丢失,将深度差距较大的特征图进行融合会破坏浅层特征图中小目标的特征信息^[17-18].因此,如何有效融合各特征图中的特征信息,是更好实现舰船目标多尺度检测的关键.

针对SAR图像舰船小目标检测中的问题,本文提出一种基于特征增强的SSD目标检测算法(feature enhancement of SSD, FESSD).首先,为避免网络产生大量的冗余通道,精简骨干网络VGG16,将各卷积层的通道数减少至原来的1/3以提取舰船目标的特征;然后提出一种混合多特征提取模块(hybrid feature extraction module, HFE module),通过在浅层增加HFE模块增强网络对不同尺寸舰船目标的特征提取能力,使模型更加适合SAR舰船目标检测任务;最后,提出一种邻近特征融合模块(neighbor feature fusion module, NFF module)增强各层特征信息,进一步提高小目标的检测能力.在公开的SAR舰船数据集SSDD上的实验充分验证了所提出方法的有效性,同时通过消融实验进一步验证了所提出各个模块的有效性.

1 SSD检测模型

本文提出的FESSD模型基于SSD模型进行改进.SSD算法以VGG16和附加网络作为骨干网络进行特征提取,提取出的6层特征图分别为conv 4_3、FC7、conv 8_2、conv 9_2、conv 10_2、conv 11_2,特征图尺寸大小分别为 38×38 、 19×19 、 10×10 、 5×5 、 3×3 、 1×1 .该算法在感受野较小的大特征图中检测小目标,在感受野较小的小特征图中检测大目标,这种多尺度目标检测方法有效提高了舰船目标检测算法的性能.

SSD基于前馈CNN进行特征提取,首先在6个特征层生成不同宽高比的先验框.在训练阶段,将先验框与真实框计算IoU(intersection over union)进行正负样本的匹配,并采用难例样本挖掘技术保证正负样本比例接近1:3,最后通过分类损失和位置损失的加权和表示为损失函数进行训练,具体表示为

$$L(x, c, l, g) = \frac{1}{N} [L_{\text{conf}}(x, c) + aL_{\text{loc}}(x, l, g)]. \quad (1)$$

其中: N 为候选框与真实框匹配的数量, $L_{\text{conf}}(x, c)$ 为分类损失, $L_{\text{loc}}(x, l, g)$ 为位置损失, $a = 1$ 为损失权重, x 为输入图像, c 为标签类别, l 为预测框, g 为真实框.在预测阶段,由于预测框数量较多,通过非极大值抑制算法(non-maximum suppression, NMS)对预测框进一步筛选以消除置信度低于阈值的重复框和无类别框,最后输出检测结果.

2 改进的SSD舰船目标检测算法

2.1 FESSD模型结构

经典的目标检测算法是针对3通道光学图像的,而SAR图像采用不同极化方式获得单通道图像,且特征信息较少,直接采用光学图像下的目标检测算法对SAR图像舰船目标检测而言增加了网络的冗余信息.此外,SSD算法虽然采用多尺度特征预测方法,但是SAR图像具有噪声信息多、特征信息少且目标尺度复杂的特点,SSD算法在检测时负责中小目标检测的conv 4_3、FC7、conv 8_2浅层特征图无法充分提取目标的特征信息,使得小目标舰船检测的漏检率和虚警率较高.并且由于骨干网络的下采样操作,使得在深层特征图中丢失了原始图像中大量细节信息,不利于SAR舰船目标的识别和定位.

鉴于此,基于SSD提出一种适用于SAR图像舰船检测的FESSD算法.该算法主要对SSD做出如下3个方面的改进:1)将骨干网络VGG16全部卷积层的通道维数减少至原1/3,模型显著轻量化,将其命名为Simplify-VGG16.同时,轻量化后的骨干网络不必依赖分类任务的预训练模型,可采用SSDD这类小数据集直接训练检测模型.2)参考RFBNet^[19]和具有

矩形感受野的非对称卷积核设计混合多特征提取模块.在负责中小目标检测的conv4_3、FC7和conv8_2特征图后增加HFE模块,根据SAR舰船目标的特点形成与其匹配的感受野,进一步提取浅层特征图中小目标的语义信息特征.3)参考DSSD(deconvolutional single shot detector)特征融合思想,设计邻近特征融合模块,将浅层的位置信息与邻近特征图的高层语义信息更科学地融合,提高小目标的检测能力.

FESSD算法整体结构框架如图1所示.为了使NFF模块更好地工作的同时提高小目标的检测能力,网络采用320×320尺寸的输入图像,经骨干网络提取形成40×40、20×20、10×10、5×5、3×3、1×1大小的特征图.由于采用了轻量化的Simplify-VGG16骨干网络结构,形成的特征图通道维数也显著减少,分别为192、384、192、96、96、96.浅层特征图conv 4_3、FC7和conv 8_2分别经HFE模块进一步提取特征,最后经NFF模块仅将本层与相邻的两层高层特征图进行融合形成最终的特征图.之后与SSD方法相同,将特征图输入检测网络,与不同宽高比的先验框进行匹配以检测不同尺度大小的SAR舰船目标,并通过NMS操作筛选检测结果.

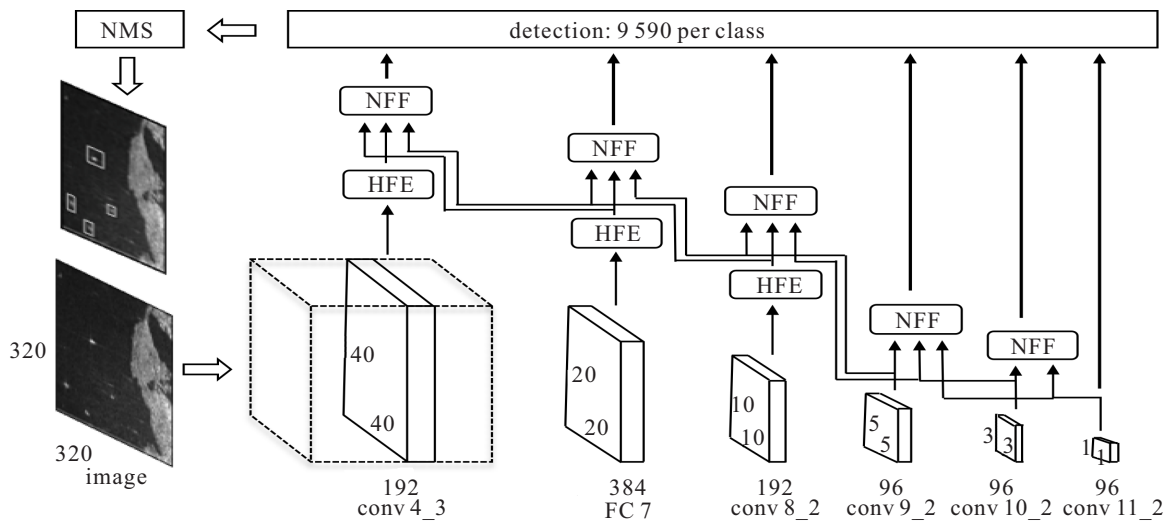


图1 FESSD算法框架

2.2 混合多特征提取

SSD检测算法本身存在对于小目标和“窄而长”目标检测效果不佳的问题,而且不能通过调整先验框的长宽比例得以解决.SAR图像中舰船目标尺寸复杂,存在数量较多的小目标.对数据集SSDD中舰船目标长宽比进行统计发现,部分舰船目标的长宽比低于0.5或高于3,而SSD等目标检测模型大多采用正方形的卷积核,导致感受野大小与舰船目标的宽高比存在不匹配的现象,感受野的单一性影响对不同宽高

比舰船目标的检测.因此,直接将SSD目标检测模型应用到SAR舰船目标检测任务中其适应性较差,无法充分提取舰船目标特征,容易漏检和错检.

鉴于此,提出混合多特征提取模块对SSD进行改进,HFE模块结构如图2所示.HFE参考RFBNet的receptive field block设计HFE模块的分支结构,首先用1×1卷积核将输入特征图的通道数降维至前一层的1/8或1/4以减少计算量;然后通过两种类型的卷积核,分别为1×k和k×1的非对称卷积核以及3×3不同

空洞率的空洞卷积核. 其中 $1 \times k$ 和 $k \times 1$ 的卷积核可以提供更加适合SAR舰船目标的矩形感受野, 本文 k 取值为3、5. 浅层特征图conv 4_3和FC7尺寸较大且具有较多的底层特征信息, 为了保留特征图的有效信息, 采用不同空洞率的空洞卷积在不增加计算量的同时扩大了视觉感受野. 空洞卷积等效卷积核尺寸与空洞率之间的关系为

$$K = D_K + (D_K - 1)(d - 1). \quad (2)$$

其中: K 为空洞卷积核等效于普通卷积核的大小, D_K 为实际卷积核大小, d 为空洞率. 在HFE模块中, 卷积核大小为 3×3 , 为了避免感受野过大, 同时弥补空洞卷积带来的“网格效应”, 根据HDC (hybrid dilated convolution) 设计原则^[20], 设计 $d = 2$ 和 $d = 3$ 两种空洞率的空洞卷积, 各空洞卷积系数不同且其最大公约数不大于1, 符合文献[21]的空洞卷积设计原则. 然后, 将每个分支经 1×1 卷积层映射后的输出

通道连接在一起, 此时特征通道数与输入通道数相同. 最后经过 1×1 卷积层进一步融合不同分支的通道, 与短路连接的原始输入特征进行元素相加操作.

图3为FESSD算法与SSD算法在conv 4_3、FC7、conv 8_2层输出的特征热力图对比结果, 由于特征图分辨率较小不便于观察, 对其进行放大. 图3(b)~(d)为SSD算法输出特征热力图, 图3(e)~(g)为FESSD经HFE模块进一步提取特征后输出的特征热力图. 显然, 经过HFE模块提取的特征, 图3(e)比图3(b)更加匹配SAR舰船目标本身, 较小的目标仍能高亮显示, 具有更强的语义信息, 同时表明HFE模块的多样化感受野也更加适合SAR舰船目标. 由于HFE模块中空洞卷积存在更大的感受野, 相比SSD算法可以使网络的注意力集中于海域以及沿岸的区域. 图3(f)和图3(c)的特征图负责中小目标的舰船目标检测, 但由于网络的下采样层使小目标特征进一步减

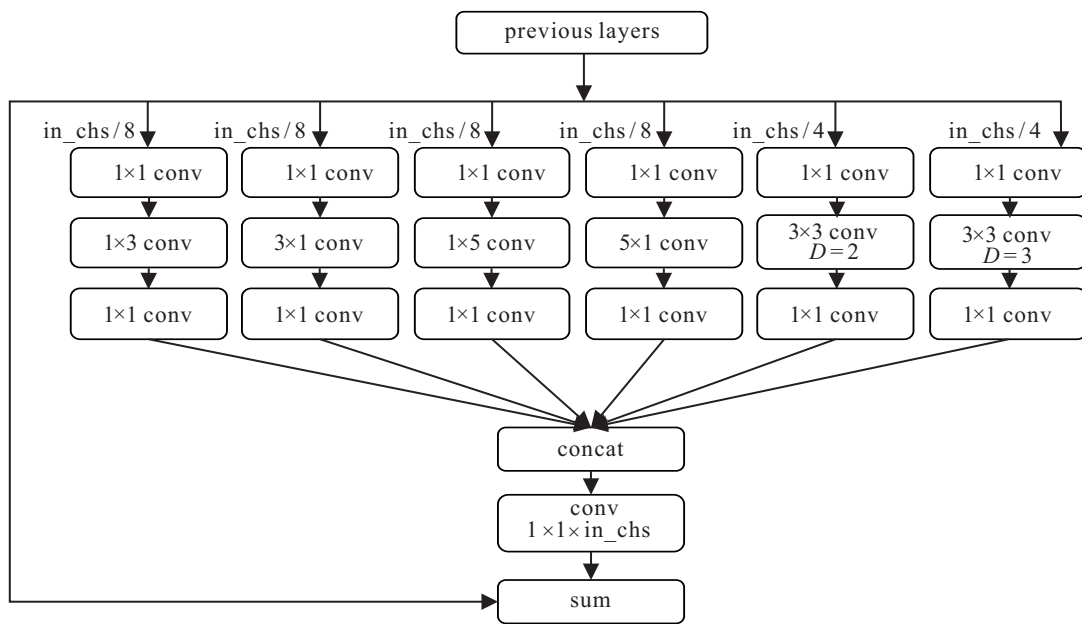


图2 HFE模块结构

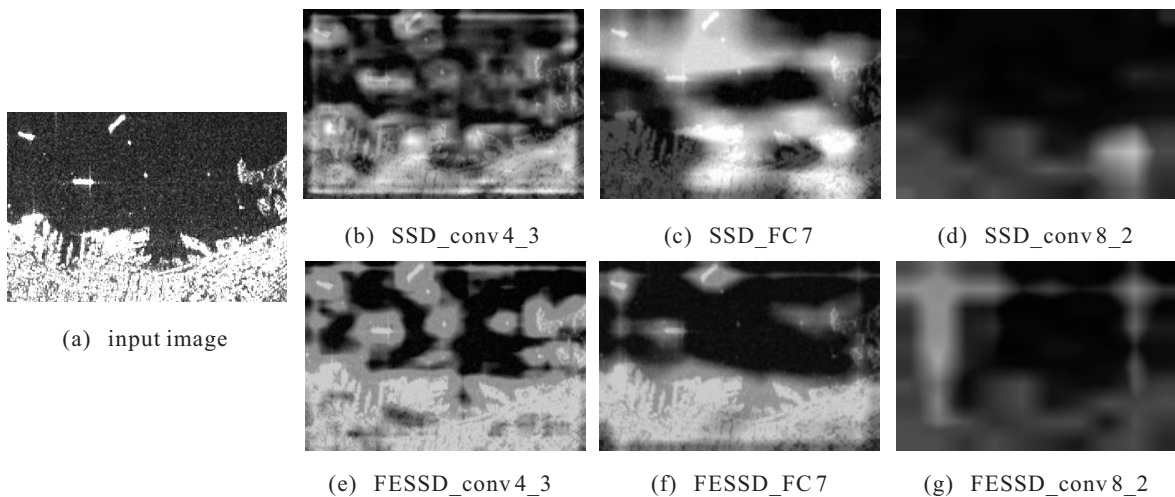


图3 混合多特征提取前后特征图对比

少,图3(c)中小目标已经失去网络的关注,但是图3(f)相比(c)小目标更加高亮,小目标仍能得到网络的关注. 并且由于感受野进一步扩大,HFE模块的感受野会向内陆伸展,但是沿岸区域依然是网络注意力集中的区域. 图3(g)和图3(d)特征图仅有10像素大小,此时小目标完全丢失. 由于HFE模块中的空洞卷积具有更大的感受野,图3(g)相比(d)网络的注意力更集中至海域. 图3(d)由于感受野相对较小,会将大片白色内陆误认为大型舰船目标,而使内陆区域获得较大权重,海域获得较小权重,进一步影响特征融合操作时海域中正确目标的权重值,进而影响舰船目标的检测结果.

本文提出的HFE模块通过并行的6种不同的特征提取网络,为模型引入多种特征提取方式,不仅深化了网络,而且能够更加充分地提取SAR图像中舰船目标的特征,提升检测效果. 在后续的第3.4节中的消融实验将详细分析HFE模块的有效性.

2.3 邻近特征融合

在光学图像目标检测中,为了提高小目标检测能力,往往会通过特征融合的方法将高层特征的语义信息与底层的特征信息进行融合,然后进行预测. 如,FPN提出一种自顶向下的特征融合方式,PANet^[22]提出一种双向特征融合方式,BiFPN通过网络结构搜索提出了更加复杂的特征融合方式. 但是在SAR图像舰船检测中,小尺寸与大尺寸舰船目标相比特征信息少,并且由于网络的下采样作用,小目标在高层的特征图中仅有很少的特征信息,甚至会全部丢失. 若采用常用的特征融合策略,则会将浅层

特征与相距较远的高层特征图进行融合,此时高层语义特征中含有大量信息噪声,会将高层特征图中的噪声融入到低层特征图中,破坏浅层小目标的特征甚至导致消失,不利于SAR图像中舰船目标检测.

鉴于此,在FESSD算法中提出邻近特征融合模块,仅将当前特征与其相距较近的两层高层特征图进行融合,以此避免将高层的噪声信息引入到低层特征中,使得融合后的特征图同时具有深层特征图的语义信息和浅层特征图的特征信息. 图4为FESSD结构中第1个NFF模块的结构,对于conv4_3特征层,仅将邻近的FC7和conv8_2高层特征图进行融合. 除conv10_2特征层仅与conv11_2融合外,其余NFF模块都遵循这种融合规律. 为了使网络进一步学习到特征信息,参考DSSD中^[23]反卷积层结构,设计NFF模块反卷积分支. 深层的特征图首先分别经过反卷积层恢复到与低层特征图相同的特征维度大小,并经过3×3卷积层和BatchNorm层;然后将两反卷积分支网络输出的同维度特征进行元素相加操作,得到融合后的深层特征图. 浅层特征图conv8_2经过两个3×3卷积层和BatchNorm层后,与上述融合后的深层特征图进行元素相加操作,得到最终的输出特征,至此便完成了邻近特征融合. 所提出的NFF模块除NFF_5仅有1条深层特征反卷积网络分支外,其余均有2条.

所提出的NFF模块通过更适合SAR图像舰船目标的邻近特征融合方式,能够有效避免在特征融合阶段对目标的空间信息和语义信息破坏造成小目标的检测问题. 在后续的第3.4节的消融实验将进一步分析NFF模块的有效性.

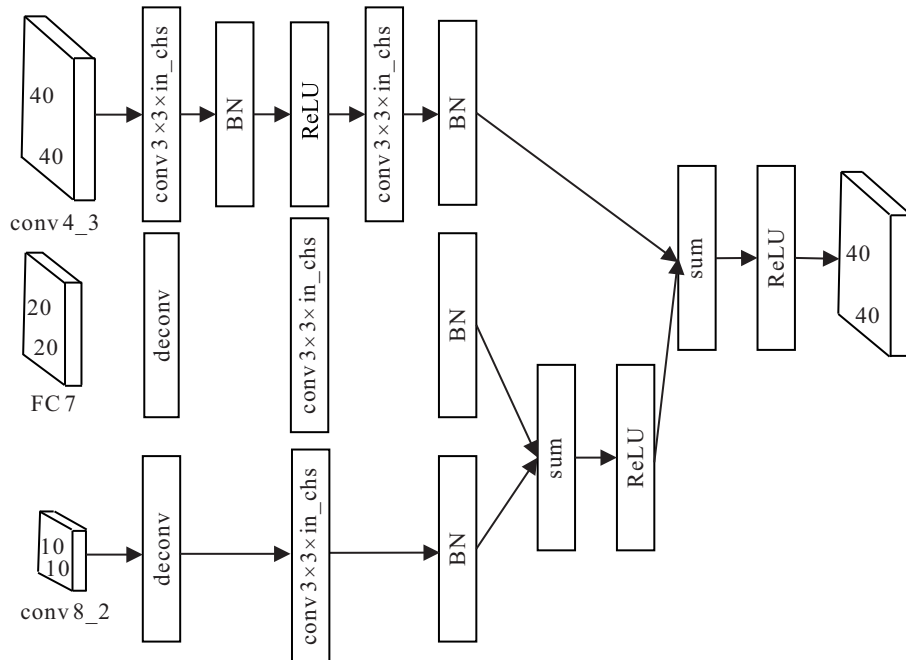


图4 NFF_1模块结构

3 实验结果与分析

3.1 实验平台与超参数设置

本文使用的计算机硬件平台 CPU 为 Intel(R) Core(TM) i5-6300HQ, GPU 为 NVIDIA GTX1060. 操作系统为 Ubuntu16.04, 采用 Pytorch1.7.0 深度学习框架, 编程语言为 Python.

实验基于随机初始化网络结构参数进行模型训练, 训练的批处理大小为 8, 初始学习率为 0.001, 衰减系数为 0.1, 总训练轮数为 300. 优化算法采用 SGD, 动量因子参数为 0.9.

3.2 数据集介绍

为了更好地评价模型性能, 实验采用公开的 SAR 舰船目标数据集 SSDD, 该数据来源包括卫星 RadarSat-2、TerraSAR-X 和 Sentinel-1, 包含 1~15 m 不同的分辨率. 数据集按照 PASCAL VOC 格式建立, 标注了在不同场景下(近岸、孤立)像素值大于 3 的多尺度舰船目标, 共 1 160 幅图像, 包含 2 346 艘舰船. 按照 7:1:2 的比例, 将数据集划分为训练集、验证集和测试集.

3.3 评价指标

使用的评价指标为平均准确率 (average precision, AP)、检测速率 (frames per second, FPS)、参数量 (parameters, Params) 以及浮点运算数 (floating point operations, FLOPs). FPS 定义为每秒处理图像的帧数; Params 为网络模型中的权重和偏置总量; FLOPs 为模型计算量指标, 衡量模型计算复杂度.

3.4 实验分析

3.4.1 对比实验

本文评估了 FESSD 算法的性能, 将几种典型的多尺度目标检测算法应用于 SAR 图像舰船目标检测并进行对比. 为保证结果公平, 均在本文实验平台重新进行训练, 除所提出的 FESSD 模型外, 其他模型均采用加载预训练模型的迁移学习方式进行训练, 实验结果如表 1 所示. 由表 1 可知, 所提出 FESSD

算法的 AP、FPS 性能指标均优于其他检测算法, 且模型参数量和计算量也进一步减小. 从检测精度上看, FESSD 算法的 AP 高于其他检测算法, FESSD 的输入为 320×320 图像, 与其输入图像尺寸相同的 DSSD、YOLOv3 和 YOLOv4 模型相比, AP 分别提高了 4.61%、3.25%、1.94%. 另外, 将输入图像放大能够显著提高小舰船目标的检测效果, 虽然 Faster RCNN、RetinaNet 和 RFBNet 模型的输入图像尺寸远大于 FESSD, 但是 FESSD 算法相对这些大尺寸输入图像模型检测效果更好, AP 分别提高了 4.81%、8.26%、5.91%. 造成这样结果的主要原因如下: Faster RCNN 和 RFBNet 的 backbone 与 FESSD 都采用了 VGG16, 它们的特征提取能力相似, 但是 FESSD 由于采用了 HFE 模块, 相对其他模型具有更强的特征提取能力. 并且虽然其他模型也具有特征融合能力, 但是相比之下 FESSD 采用 NFF 模块能更科学地对特征进行融合, 增强小目标的特征, 提升网络的检测能力. RetinaNet 由于采用了更深的 ResNet50 骨干网络, 相比 VGG16 具有更强的特征表达能力. 但是, FESSD 算法采用的 HFE 模块具有更适合 SAR 舰船目标的感受野, 相对一味地加深模型深度, 采用与目标更加匹配的感受野是更有效的. 从检测速度上看, 所提出的 FESSD 算法能够满足实时检测且检测速度较快, 相较于其他模型提升幅度也较高. 虽然采用了较小的输入图片尺寸, 但是对小目标也具有较好的检测能力, 且小尺寸输入图片意味着在模型部署时需要更小的内存空间, 降低硬件成本. FESSD 算法检测时的 FPS 达到了 41.34 帧, 虽然采用了 HFE 模块和 NFF 模块, 但是并未大幅度增加模型的时间复杂度. 从模型大小上看, FESSD 模型具有较小的模型, 在模型部署时占用较少的存储空间. FESSD 的 Simplify-VGG16 骨干网络相对 VGG16 参数量大约减少了 1/3, 虽然 HFE 模块和 NFF 模块增加了模型的参数量, 但是相对 SSD 模型的参数量依然减少了 5.06 M, 相比于其他检

表 1 本文方法与其他经典目标检测算法对比结果

模型	Backbone	Input size	AP _(IoU=0.5) /%	FPS	Params/M	FLOPs/G
SSD ^[9]	VGG16	300×300	89.75	34.2	23.8	30.6
DSSD ^[23]	ResNet101	320×320	88.83	15.7	121.8	35.1
Faster RCNN ^[6]	VGG16	600×600	88.63	6.3	136.69	184.6
RetinaNet ^[24]	ResNet50	600×600	85.18	14.4	36.33	72.5
RFBNet ^[19]	VGG16	512×512	87.53	15.4	34.44	137.0
YOLOv3 ^[7]	DarkNet53	320×320	90.19	33.3	61.49	154.9
YOLOv4 ^[8]	CSPDarkNet53	320×320	91.50	30.9	63.93	141.4
FESSD(our)	Simplify-VGG16	320×320	93.44	41.8	18.74	10.2

测模型也具有很小的参数量. 从计算量上看, FESSD模型有10.2 GFLOPs, 仅为SSD模型计算量的1/3, 虽然增加了HFE模块和NFF模块, 但计算量也远小于其他检测模型. 特别是与输入图像尺寸相同的目标检测模型相比, FESSD在具有较少计算量的同时又保持了较高的检测精度. 综上所述, 所提出的FESSD模型相对于其他检测模型在SAR图像舰船目标检测中具有更高的综合性能.

图5为4种典型的困难场景下不同模型对SAR图像舰船检测结果的对比. 图5(a)为包含靠岸舰船目标和海面孤立舰船在内的复杂场景下的SAR舰船图像, 可以看出, 所有算法对海面的孤立目标具有很好的检测能力, 但是对靠岸的舰船目标漏检情况比较严重. 由图5的热力图也可以看出, 本文算法HEF模块具有更加丰富的感受野, 可以将注意力放到舰船目标潜在的区域, 在目标尺度复杂的场景下本文算法对舰船目标检测依然有较大提升. 图5(b)为海面密集型小目标舰船目标, SSD算法等其他算法对小目

标检测效果差, 漏检严重, YOLOv3和YOLOv4检测效果较好, 其中YOLOv4检测结果与本文算法结果较为接近, 主要原因是本文仅采用SSD最原始的数据增强方式, 而YOLOv4采用了大量的数据增强技术, 特别是针对小目标的Mosaic方法对小目标数据集进行了扩充, 但是其漏检率相比本文算法依然较高. 图5(c)为港口舰船目标, 可以看出, 对于相对较大的目标, 各算法均具有很好的检测能力, 但是对于小尺寸舰船, 由于受到陆地的严重干扰导致漏检率较高. 本文算法由于网络注意力集中于海面以及沿岸, 不存在Faster RCNN中的错检情况, 且相比其他算法更容易发现小尺寸的临岸舰船目标, 对于港口的沿岸小舰船具有很好的检测能力. 图5(d)为河道内舰船, 由于河道内的舰船目标稀疏且特征明显, 除YOLOv3存在漏检情况外, 各算法检测效果较好, 但本文算法在未漏检的情况下, 依然能够以较高的置信度检出目标舰船. 综上所述, 本文算法在真实的SAR图像舰船检测的复杂场景中具有较高的综合检测性能.




图5 不同模型对SAR图像舰船检测结果对比

3.4.2 消融实验

为分析所提出两种即插即用的特征增强模块(即HFE和NFF)对SAR图像舰船目标检测AP的影响,设置不同的特征增强组合方式进行对比分析,并选取典型的特征融合网络FPN以及内部有跳跃连接的BiFPN进一步加以验证.当输入图像尺寸为 320×320 时,各模块实验效果对比如表2所示.

由表2可知,在SSD检测算法基础上,根据SAR图像特性将骨干网络的通道数减少至1/3可以有效减少网络的冗余信息,大幅度减少了模型参数量且精度仅下降1.05%,同时也使模型的时间复杂度降低,检测时速度达到63.37 FPS.在此基础上,增加特征融合模块进行实验.当仅增加NFF模块时,由于NFF模块中存在大量反卷积层,使模型参数量增加到18.21 M,反卷积核也会使模型学习到舰船的特征信息,并且有特征信息的相互融合作用,两者使模型AP有小幅度提升.模型中仅增加NFF模块对整体检测性能提升不大,原因主要是骨干网络对目标特征信息提取不完全,NFF模块仅对有限的特征信息进行了融合.当仅增加FPN模块时,由于其自下而上的特征融合方式不利于小目标舰船检测,导致算法AP下降较多.当仅增加BiFPN模块时,虽然其并未提升算法AP,但其内部存在的短路连接会最大程度地保留原始特征,使得舰船检测AP稳定.当仅增加HFE模块时,模型参数量仅增加0.53 M,虽然增加了模型的复

杂度,使模型检测速度降低到48.64 FPS,但是其检测精度AP由88.70%提高至91.81%,这表明HFE模块提供的多样性感受野能够有效提高模型对小目标舰船的检测能力.此外,为了进一步验证NFF模块的有效性,在浅层网络中添加HFE模块对舰船特征信息进一步提取,之后添加NFF模块对邻近特征进行融合,形成本文所提出的FESSD算法.增加NFF模块与HFE模块的检测算法相对仅增加HFE模块,其AP提升了1.63%,而仅添加NFF模块相对仅做通道缩减的检测算法AP提升了1.22%.所以,NFF模块可以有效融合提取到的特征信息.在增加FPN模块或BiFPN的基础上,再增加HFE模块对舰船特征进一步提取,检测模型的AP分别提高了1.71%和2.35%,进一步表明了HFE模块的有效性.所提出的FESSD算法基于SSD算法,通过增加上述两种模块,可以有效提升SSD算法的综合检测性能.从检测精度上看,FESSD算法AP达到93.44%,较SSD算法提升3.69%;从检测速度上看,FESSD算法检测速度为41.80 FPS,较SSD算法提升7.6 FPS;从模型参数量上看,FESSD算法参数量为18.74 M较SSD算法减少5.06 M.

上述消融实验结果表明,所提出的FESSD算法中HFE模块能够有效提高模型对SAR图像舰船目标,特别是小舰船目标的特征提取能力,而NFF模块也能有效融合特征图中的特征信息,提高模型对小舰船目标的检测能力.

表2 两种模块对SAR图像舰船目标检测的影响

SSD	Simplify-VGG16	HFE	NFF	FPN	BiFPN	AP _(IoU=0.5) /%	FPS	Params/M
√						89.75	34.20	23.80
√	√					88.70	63.37	3.69
√	√		√			89.92	42.34	18.21
√	√			√		88.28	45.31	4.15
√	√				√	88.60	33.80	3.99
√	√	√				91.81	48.64	4.22
√	√	√	√			93.44	41.80	18.74
√	√	√		√		89.99	36.86	4.68
√	√	√			√	90.95	24.94	4.52

4 结论

本文针对当前基于CNN的SAR图像舰船目标检测时存在的问题,提出了一种FESSD舰船目标检测算法.该算法根据SAR图像的特性精简SSD算法的网络结构,提高算法的检测效率.提出HFE模块,为网络引入适合SAR图像舰船目标的多样化感受野,提取舰船目标的深层特征,同时指出NFF模块能有效融合所提取的特征,进一步增强舰船目标的特征

信息,有效提升了网络在各场景下小目标的检测效果.实验结果表明,将所提出方法与基准模型以及其他多种深度学习检测算法相比,前者在速度、精度和参数量方面均表现出良好的性能.通过消融实验验证了所提出各模块的有效性,从实际场景检测结果也可以看出,所提出方法有效降低了舰船目标检测的漏检情况和虚警率,具有较高的综合性能.

参考文献(References)

- [1] Allard Y, Germain M, Bonneau O. Ship detection and characterization using polarimetric SAR data[C]. Harbour Protection Through Data Fusion Technologies. Berlin, 2009: 243-250.
- [2] 彭书娟, 曲长文, 李健伟. K 近邻优化估计的SAR图像建模与目标检测算法[J]. 控制与决策, 2020, 35(9): 2199-2206.
(Peng S J, Qu C W, Li J W. K nearest neighbors optimized estimation algorithm for SAR image statistical modeling and target detection[J]. Control and Decision, 2020, 35(9): 2199-2206.)
- [3] Grigorescu S, Trasnea B, Cocias T, et al. A survey of deep learning techniques for autonomous driving[J]. Journal of Field Robotics, 2020, 37(3): 362-386.
- [4] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]. IEEE Conference on Computer Vision and Pattern Recognition. Columbus, 2014: 580-587.
- [5] Girshick R B. Fast R -CNN[C]. Proceedings of the 2015 IEEE International Conference on Computer Vision. Santiago, 2015: 1440-1448.
- [6] Ren S Q, He K M, Girshick R, et al. Faster R -CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.
- [7] Redmon J, Farhadi A. YOLOv3: An incremental improvement[J/OL]. 2018, arXiv: 1804.02767.
- [8] Bochkovskiy A, Wang C Y, Liao H Y M. YOLOv4: Optimal speed and accuracy of object detection[J/OL]. 2020, arXiv: 2004.10934.
- [9] Liu W, Anguelov D, Erhan D, et al. SSD: single shot MultiBox detector[C]. Computer Vision. Berlin, 2016: 21-37.
- [10] Law H, Deng J. CornerNet: Detecting objects as paired keypoints[J]. International Journal of Computer Vision, 2020, 128(3): 642-656.
- [11] Lin T Y, Dollár P, Girshick R, et al. Feature pyramid networks for object detection[C]. IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, 2017: 936-944.
- [12] Tan M X, Pang R M, Le Q V. EfficientDet: Scalable and efficient object detection[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, 2020: 10778-10787.
- [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.
(Li J W, Qu C W, Peng S J, et al. Ship detection in SAR images based on convolutional neural network[J]. Systems Engineering and Electronics, 2018, 40(9): 1953-1959.)
- [14] 李健伟, 曲长文, 彭书娟. 基于级联CNN的SAR图像舰船目标检测算法[J]. 控制与决策, 2019, 34(10): 2191-2197.
(Li J W, Qu C W, Peng S J. A ship detection method based on cascade CNN in SAR images[J]. Control and Decision, 2019, 34(10): 2191-2197.)
- [15] Wang J Z, Lu C H, Jiang W W. Simultaneous ship detection and orientation estimation in SAR images based on attention module and angle regression[J]. Sensors: Basel, Switzerland, 2018, 18(9): 2851.
- [16] 韩子硕, 王春平, 付强, 等. 基于超密集特征金字塔网络的SAR图像舰船检测[J]. 系统工程与电子技术, 2020, 42(10): 2214-2222.
(Han Z S, Wang C P, Fu Q, et al. Ship detection in SAR images based on super dense feature pyramid networks[J]. Systems Engineering and Electronics, 2020, 42(10): 2214-2222.)
- [17] Deng C F, Wang M M, Liu L, et al. Extended feature pyramid network for small object detection[J]. IEEE Transactions on Multimedia, 2021, 4273 (99): 1.
- [18] Tang X, Du D K, He Z Q, et al. PyramidBox: A context-assisted single shot face detector[C]. Computer Vision. Berlin, 2018: 797-813.
- [19] Liu S, Huang D. Receptive field block net for accurate and fast object detection[C]. Proceedings of the European Conference on Computer Vision. New York, 2018: 385-400.
- [20] Wang P Q, Chen P F, Yuan Y, et al. Understanding convolution for semantic segmentation[C]. IEEE Winter Conference on Applications of Computer Vision. Lake Tahoe, 2018: 1451-1460.
- [21] 刘涛, 汪西莉. 采用卷积核金字塔和空洞卷积的单阶段目标检测[J]. 中国图象图形学报, 2020, 25(1): 102-112.
(Liu T, Wang X L. Single-stage object detection using filter pyramid and atrous convolution[J]. Journal of Image and Graphics, 2020, 25(1): 102-112.)
- [22] Liu S, Qi L, Qin H F, et al. Path aggregation network for instance segmentation[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, 2018: 8759-8768.
- [23] Fu C Y, Liu W, Ranga A, et al. DSSD: deconvolutional single shot detector[J/OL]. 2017, arXiv: 1701.06659.
- [24] Lin T Y, Goyal P, Girshick R, et al. Focal loss for dense object detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(2): 318-327.

作者简介

严春满(1971—), 男, 副教授, 博士, 从事模式识别、人工智能等研究, E-mail: YanCha02@163.com;

王铖(1997—), 男, 硕士生, 从事人工智能、模式识别、嵌入式系统的研究, E-mail: 610487244@qq.com.

(责任编辑: 郑晓蕾)