

基于改进 YOLOv5s 的光学遥感图像舰船分类检测方法

周旗开¹, 张伟¹, 李东锦², 牛福^{1*}

¹军事科学院系统工程研究院后勤科学与技术研究所, 北京 100071;

²北京控制与电子技术研究所, 北京 100038

摘要 针对遥感图像舰船检测中存在的场景复杂、尺度多样造成的错漏检问题, 提出一种基于改进 YOLOv5s 的轻量级舰船分类检测方法, 以在设备计算能力受限前提下, 实现对舰船的实时快速分类检测。该方法将一种轻量、高效的通道注意力应用到主干特征提取网络中, 使得构成的新的特征提取网络在场景复杂的遥感图像中对舰船具有更强的辨识能力; 将特征提取网络得到的不同层次特征图输入到加权双向特征金字塔结构中, 优化主干网络高低阶段特征的融合, 并在遥感图像舰船数据集上进行实验。结果表明, 改进后的网络模型的平均均值精度由原始的 83.9% 提高至 89.2%, 对航母、军舰、民船、潜艇的平均精确度分别提升 1.6 个百分点、0.9 个百分点、8.8 个百分点、9.5 个百分点, 同时平均检测速度和网络复杂度明显优于其他算法。

关键词 遥感图像; 目标检测; YOLOv5s; 注意力机制; 特征金字塔

中图分类号 TP751.1

文献标志码 A

DOI: 10.3788/LOP202259.1628008

Ship Classification and Detection Method for Optical Remote Sensing Images Based on Improved YOLOv5s

Zhou Qikai¹, Zhang Wei¹, Li Dongjin², Niu Fu^{1*}

¹Academy of Systems Engineering of Academy of Military Science of Chinese PLA, Beijing 100071, China;

²Beijing Institute of Control and Electronic Technology, Beijing 100038, China

Abstract Owing to the fault and leak detection problems caused by complex scenes and diverse scales in remote sensing image ship detection, a lightweight ship classification detection method based on improved YOLOv5s is proposed herein to realize real-time rapid ship classification and detection despite limited equipment computing capability. This method applies a lightweight and efficient channel attention technique to the backbone feature extraction network to obtain a novel feature extraction network with an improved ability to identify ships in complex remote sensing images. The feature maps with different levels obtained from the feature extraction network were input into the weighted bidirectional feature pyramid structure to optimize the fusion of high and low stage features of the backbone network, and experiments were conducted on the ship dataset of remote sensing images. The results show that the mean average precision of the improved network model has increased from 83.9% to 89.2% and the average precision for detecting aircraft carriers, warships, civil ships, and submarines has increased by 1.6 percentage points, 0.9 percentage points, 8.8 percentage points, and 9.5 percentage points, respectively. Additionally, the average detection speed and network complexity are considerably better than the other algorithms.

Key words remote sensing image; object detection; YOLOv5s; attention mechanism; feature pyramid

1 引言

遥感图像舰船检测在军民用上都有着广泛的应用^[1]。在军用方面, 对舰船的分类检测有利于及时分析敌方海军基地兵力部署情况, 提高海上战场态势感

知能力, 为作战决策提供及时的情报信息; 在民用方面, 舰船的分类检测可以对海上失事船只及时进行海洋搜救, 通过卫星辅助对遇险舰船进行搜寻, 提高搜救的效率, 为营救遇难人员争取宝贵的救援时间。因此, 对遥感图像舰船目标快速准确的检测具有重要意义。

收稿日期: 2021-12-29; 修回日期: 2022-02-16; 录用日期: 2022-02-25

通信作者: *niufu@vip.sina.com

传统的舰船检测方法主要分为 4 种:基于灰度信息统计特征的方法、基于视觉显著性的方法、基于模板匹配的方法和基于分类学习的方法^[2]。传统方法计算简单,但某些方法往往只针对某一特定的场景,在复杂的环境中鲁棒性较差,因此传统方法在高分辨率遥感图像的目标检测中适用性不强。随着深度学习的快速发展,将深度学习目标检测算法应用于遥感图像舰船检测成为主要方法。基于深度学习的舰船检测算法主要可以分为两类:一种为区域型,代表算法有 R-CNN (regions with CNN features)^[3]、Fast R-CNN (fast region-based convolutional network)^[4]、Faster R-CNN (faster regions with convolutional neural network)^[5]等;另一种是回归型,代表算法有 SSD (single shot MultiBox detector)^[6]、YOLO (you only look once)^[7-10]系列,其中 2021 年 6 月份,Ultralytics 团队^[11]在 YOLOv4 的基础上提出 YOLOv5 模型。近些年已有不少学者在这方面进行了研究。汪鹏等^[12]在 YOLOv3 网络的基础上,利用密集连接块来提取深层次的图像特征,解决复杂场景下的目标检测精度低的问题。徐志京等^[13]提出一种基于快速区域卷积神经网络的检测方法,该方法采用多尺度融合特征金字塔网络进行特征融合,适应舰船在遥感图像中的特性。

YOLOv3、YOLOv4、SSD 等一阶段检测算法虽然相较于两阶段检测算法检测速度较快,但网络模型还是较大,无法满足实际轻量化部署的应用需求。以上研究通过改进网络结构等方法,一定程度上解决了一阶段算法检测精度相对较低的问题,但同时又增加网络复杂度,未权衡好检测精度和速度。针对上述问题,

本文致力于研究如何更好地提取并融合不同尺度舰船特征,解决场景复杂、舰船尺度变化多样导致检测过程中易出现错漏检的问题,并权衡检测速度与检测精度,达到检测速度和检测精度双赢的效果,提出一种轻量级多尺度增强的遥感图像舰船分类检测算法。首先,利用轻量的通道注意力机制,增强神经网络对舰船目标和图像背景的区分能力;其次,将加权双向特征金字塔网络代替原 PANet (path aggregation network)^[14]金字塔网络,更好融合不同尺度的特征图,提升对不同尺度舰船的检测效果;最后,采用公开数据集 HRSC2016^[15]作为实验数据,测试了网络性能,并与其他目标检测常用算法进行对比。

2 遥感图像舰船分类检测模型

为了处理高分辨率光学遥感图像舰船目标分类检测中存在的图像背景复杂、舰船尺度变化多样的检测难点,提出了基于 ECA (efficient channel attention for deep convolutional neural networks) 模块^[16]和 BIFPN (bi-directional feature pyramid network) 模块^[17]的目标检测网络模型 (ECA-BIFPN-YOLOv5s, 以下简称 EB-YOLOv5s)。首先,以 YOLOv5 版本中特征图宽度最小和网络深度最小的网络 YOLOv5s 为基础,将 ECA 模块融入 YOLOv5s 网络结构中,只增加少量的参数,却能提升网络提取特征的能力;其次,在特征融合阶段,使用加权 BIFPN 代替 PANet 特征金字塔,加强网络特征融合的能力,在模型轻量化的同时实现对舰船目标的高速与高精度检测。所提网络模型的总体结构如图 1 所示。

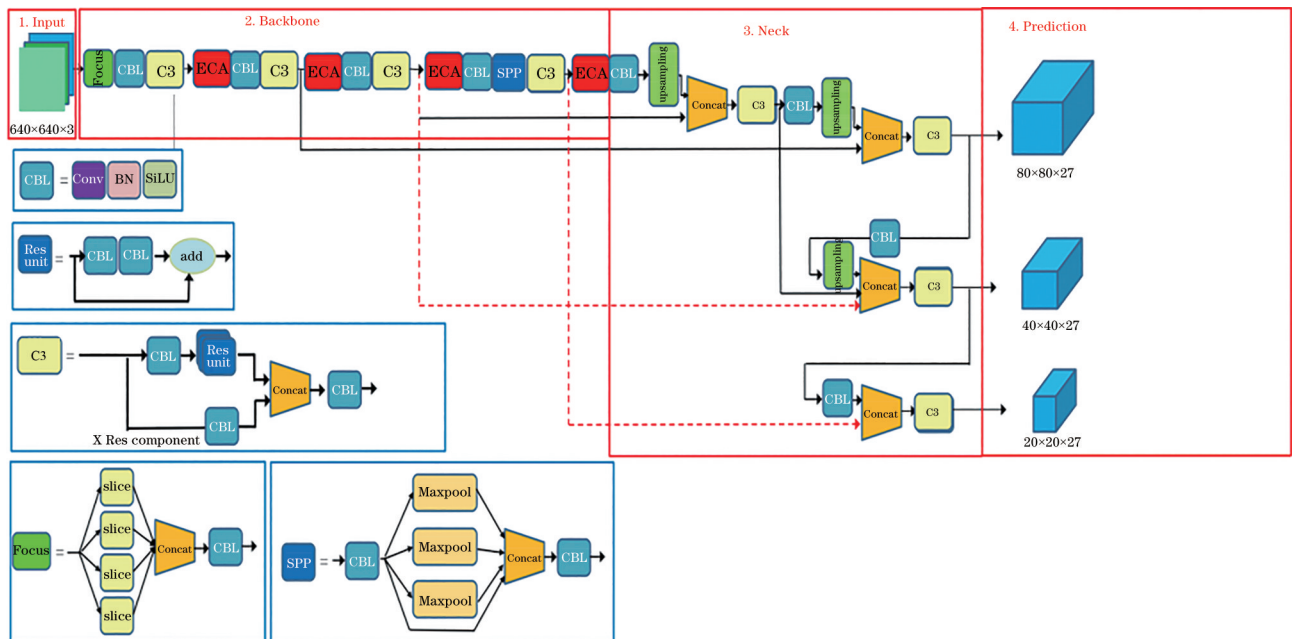


图 1 EB-YOLOv5s 结构

Fig. 1 EB-YOLOv5s structure

2.1 ECA 模块

将注意力模块插入卷积神经网络已经被证明可以有效地增强卷积神经网络丰富的表示能力^[18],能更好地捕捉遥感图像舰船目标的各种辨别性特征。在更深的层次上,注意力模块可以通过对特征映射进行重新加权求和来接收辨别能力较高的权重注意力特征。增加注意力的方法根据作用的通道可以分为两种:通道注意力(channel-wise attention)和空间注意力(spatial-wise attention)。其中,通道注意力主要探索不同特征通道之间的特征映射关系。ECA-Net是一种拥有新型高效的通道注意力机制的卷积神经网络,其在SENet(squeeze-and-excitation networks)^[19]的基础上改

进了通道注意力模块,并提出了ECA模块。

ECA机制的工作原理如图2所示。首先对输入特征进行全局平均池化(GAP),获得未降维的所有特征;之后通过尺寸为K的快速一维卷积,获取本地的跨通道交互;接着使用Sigmoid函数生成各通道的权重占比,再将原始输入特征与通道权重结合获得具有通道注意力的特征。以此模块构建的网络更易于在通道维度的基础上提取出图像的判别性特征。ECA模块通过避免降低通道维度来学习有效的通道注意力,并且以相当轻量级的方式来获取通道之间的交互信息,在复杂注意力模块获得性能提升的同时,降低了模型的复杂性,用更少的计算成本提高了检测网络的性能。




图2 ECA 模块

Fig. 2 Efficient channel attention module

高分辨率光学遥感图像由于是俯视拍摄的,图像背景信息复杂,场景中部分物体的形状、纹理和颜色等外观特征与舰船较为相似,例如厂房房顶、码头设施等;同时,遥感图像中存在一些例如船的尾迹、云雾遮挡、天气条件等干扰,使得图像画面模糊不清;另外,由于舰船类别较多,外观形态差异较大,遥感图像中不同种类舰船特征不易于区分,网络对舰船特征的辨识难度加大。在YOLOv5s主干网络提取的初始特征中,舰船共性特征显著性不足,易受图像全局背景特征干扰,受注意力可以提升网络对重要特征关注度的启发,本文将ECA模块融入YOLOv5s中,提升舰船分类检测效果。在此前研究中,蒋寰游^[20]在YOLOv5的基础卷积模块结构中的批归一化层(BN)后面加入ECA结构,以加强模型对输电线路绝缘子缺陷信息的关注程

度。文献[20]中提出的这种方法引入模块较多,共31个ECA结构,所提方法为控制模型参数量,仅在主干特征提取网络中C3模块后加入ECA模块,共4个ECA结构,实现参数量增加不多的情况下网络能够更好地区分特征之间的重要程度,从而聚焦有用的特征,增强网络对舰船特征的辨识能力。

2.2 BIFPN 模块

由于层与层之间信息的传播在深度学习网络中至关重要,低层目标位置较高层更准确,但高层特征语义信息较低层更丰富。针对高低层特征融合问题,Lin等^[21]提出了FPN来检测不同大小的物体,对大尺度特征图与小尺度特征图下采样结果进行自上到下合并,结构设计如图3(a)所示。Liu等^[14]提出了PANet以缩短特征信息在低层与高层之间的传播路径。YOLOv5




图3 特征金字塔网络。(a)传统特征金字塔网络;(b)路径聚合网络;(c)多阶段加权融合金字塔网络

Fig. 3 Feature pyramid network (FPN).(a) Traditional feature pyramid network; (b) path aggregation network; (c) multi-stage weighted fusion pyramid network

中就运用到 PANet 特征金字塔结构,具体结构设计如图 3(b)所示。Tan 等^[17]提出了基于 BIFPN 的多尺度特征融合方法,在传统的 FPN 中加入了跳跃连接,还将 FPN 仅进行自上到下特征融合替换为自上到下和自下到上的特征融合,使网络在不增加额外计算参数的同时融合更多相同尺度的特征,这样不同尺度特征能够更充分融合,对于只有一个输入的结点,将减少此结点对特征网络的贡献;并在同一尺度的特征间添加横向连接,缓解网络层级过多造成的特征信息丢失,结构设计如图 3(c)所示。

由于舰船种类丰富,舰船的大小尺度变化多样,同一张遥感图像中常常存在多种尺度的舰船目标,在目标检测中常常会出现漏检的情况。受 BIFPN 启发,采用多阶段特征加权融合金字塔策略,提高对不同尺度目标的检测能力,加权融合能够自学习各阶段特征的权重,且增加的自下而上分支优化了高层特征定位信息,能够方便、快速地进行多尺度特征融合。此前 YOLOv5 算法研究者中,郝帅等^[22]将 BIFPN 引入 YOLOv5 早期的版本,并设计了同尺度特征加权融合模块和多尺度特征加权融合模块,虽然一定程度上提高了输电线路故障检测效果,但是较大增加了网络模型复杂度。为保证网络模型的轻量化,不同于文献^[17]多次横向堆叠以及文献^[22]多模块融合的做法,所提方法仅采用一次堆叠,在网络模型复杂度增加不多的情况下,提升对舰船的分类检测效果。

3 实验数据及处理

所提网络模型训练所用实验数据来源于国内公开的 HRSC2016 数据集,为满足深度学习对大量训练样本的需求,增加模型泛化能力,采用随机缩放、翻转、亮度增强、对比度增强、颜色增强和 Mosaic 的方式进行数据增强。

3.1 评价指标

采用检测精度和检测速度来衡量模型的检测性能^[23]。检测精度指标包括召回率(R)、精确度(P)、平均精度(AP)、平均均值精度(mAP);模型检测速度指标采用检测单张图像所用的时间 t ;网络模型复杂度用网络层数(Layer)、模型权重(Weight)、网络参数量(Parameters)来评估,三者数值越大,网络模型越复杂。

召回率和精确度的计算式为

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}}, \quad (1)$$

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}}, \quad (2)$$

式中: N_{TP} 为正确的舰船检测数目; N_{FN} 为漏检的舰船数目; N_{FP} 为虚警的舰船数目。AP 值为以召回率和精确度为横纵坐标围成的面积,计算式为

$$P_A = \int_0^1 P(R) dR. \quad (3)$$

对所有类别的 AP 值取平均得到 mAP 值,计算式为

$$P_{mA} = \frac{\sum P_A}{m}, \quad (4)$$

式中: m 表示所有样本的类别个数; $P(R)$ 为精确度和召回率曲线。每张图片检测所需的时间的计算式为

$$t = \frac{T}{N}, \quad (5)$$

式中: N 为待检测遥感图像数量; T 为检测 N 张图像的总时间。

3.2 实验平台

本实验基于 Ubuntu 18.04 操作系统, Intel(R) Xeon(R) Gold 5218 处理器, 128G 内存, 64 内核, 使用 Pytorch 1.8.0 框架, 通过一台 NVIDIA Tesla T4 显卡进行训练, 显存为 32 GB。Python 版本为 3.8, CUDA 版本为 11.1.1。模型训练的迭代次数设置为 500, batch size 设置为 64。训练过程中动态调整学习率, 采用 NAG(Nesterov accelerated gradient) 优化器进行优化, momentum 设置为 0.937。采用周期性学习率进行调整和 Warm-Up 方法预热学习率, 初始学习率设置为 0.01, 学习率衰减权重为 0.0005, 使用余弦退火学习率衰减(cosine annealing)方法自动调整学习率。

为验证所提方法具有轻量化的特点,能够在设备资源有限的前提下快速准确地检测舰船目标,测试评估模型所用实验设备为一台当下普通的笔记本电脑,配置为 Intel(R) Core(TM) i5-1135G7, 内存 16 GB。

3.3 数据集

采用的数据集来源于国内公开的 HRSC2016 数据集,共包括 1061 张海面场景图像和近岸场景图像,其中大部分为近岸图像,图像分辨率为 0.4~2 m。数据集有几个特点:图像背景复杂,包括港口码头、陆地建筑、海面、小岛、薄云等;舰船尺度变化大,同一张图像舰船尺度差异较大;港口码头内舰船排列密集。HRSC2016 数据集包含三级分类,一级分类为船,二级分类为航母、军舰、商船、潜艇 4 大类,三级分类为各型号细分。其中,军舰类型主要包含航母、驱逐舰、护卫舰等 10 种类型,民舰类型主要包含货船、游轮、气垫船等多种类型,图 4 展示了数据集部分示例图像。

由于数据集部分图像同时含有三个级别的分类标注,为避免干扰,本实验筛选出 714 张不含一级分类标注的图像,将舰船图像分类标注为航母、军舰、民船、潜艇 4 种类型,构成新的 HRSC-4 数据集。按 7:1:2 随机将数据集划分为训练集、验证集和测试集。训练数据时,采用随机缩放、翻转、亮度增强、对比度增强、颜色增强和 Mosaic 的方式进行数据增强。



图 4 数据集示例图像
Fig. 4 Samples in dataset

4 实验结果与分析

为确定通道注意力卷积核 K , 通过实验对 K 进行取值后, 将对应卷积核大小的 ECA 模块融入 YOLOv5s 网络中进行对比实验, 确定 K 值; 为验证所提 EB-YOLOv5s 算法的有效性, 通过实验与其他 3 种常用的目标检测算法进行对比; 为探究所提算法中各模块对整个算法的贡献, 对 ECA 模块和 BIFPN 模块进行消融实验。以上实验均在 HRSC-4 数据集上进行, 实验过程中, 控制设备、训练超参数、迭代次数等实验条件保持一致, 得出实验结果并进行分析。

表 1 不同 K 下的实验结果

Table 1 Experimental results under different K

unit: %

| K | mAP | AP_1 (Aircraft_carrier) | AP_2 (Warship) | AP_3 (Civilian_ship) | AP_4 (Submarine) |
|-----|------|---------------------------|------------------|------------------------|--------------------|
| 1 | 85.8 | 95.0 | 95.8 | 68.3 | 84.0 |
| 3 | 87.4 | 99.2 | 94.4 | 69.1 | 86.8 |
| 5 | 84.4 | 94.6 | 95.1 | 66.4 | 81.4 |

4.2 添加 ECA 模块数量以及位置的对比实验

在确定好 ECA 模块卷积核 K 最佳取值后, 需确定 ECA 模块融入 YOLOv5 中的数量和融入位置, 让 ECA 模块在增强舰船特征提取上发挥最佳的作用, 尽可能实现对舰船分类检测的最佳效果。实验 1~3 为

4.1 通道注意力卷积核 K 取值实验

在 YOLOv5s 的主干特征提取网络融入 4 个 ECA 模块前, 需确定通道交互信息的大致范围, 即一维卷积的卷积核大小 K , K 的大小代表了局部跨信道交互的覆盖率。为尽可能降低参数量减小网络复杂度, 保证所提检测方法具有轻量化特点, 本文没有采用原论文中自适应选择卷积核的方法, 而是对 K 进行适当取值并实验, 实验结果如表 1 所示。

从表 1 可以看出, 当 $K=3$ 时, 平均均值精确度最高为 87.4%, 明显优于其他两种取值的实验结果, 故将通道注意力卷积核大小取为 3。

在主干特征提取网络 C3 模块之后分别融入 2、3、4 个 ECA 模块, 实验 4 为在 Neck 网络 C3 模块之后融入 4 个 ECA 模块, 实验编号 5 为在编号 3 的基础上在 Neck 网络中第一个 C3 模块后加入 1 个 ECA 模块, 实验结果如表 2 所示。

表 2 不同模块数量和位置下的实验结果

Table 2 Experimental results under different number and location of modules

unit: %

| Experiment No. | Number of modules | mAP | AP_1 (Aircraft_carrier) | AP_2 (Warship) | AP_3 (Civilian_ship) | AP_4 (Submarine) |
|----------------|-------------------|------|---------------------------|------------------|------------------------|--------------------|
| 1 | 2 | 86.1 | 92.8 | 95.8 | 70.9 | 84.7 |
| 2 | 3 | 87.3 | 95.2 | 95.7 | 59.3 | 81.5 |
| 3 | 4(Neck) | 81.8 | 90.0 | 94.2 | 64.8 | 78.0 |
| 4 | 4(Backbone) | 87.4 | 99.2 | 94.4 | 69.1 | 86.8 |
| 5 | 5 | 87.4 | 98.2 | 95.9 | 68.8 | 86.6 |

从表 2 中的实验 1、2、4、5 结果可以看出, 遥感图像舰船分类检测精度会随着 YOLOv5s 网络融入 ECA 模块的数量增加而变高, 精度值达到最佳后, 不再随着模块数量增大和网络层数增多而检测效果变好; 从实验 3、4 结果可以看出, 同样数量的 ECA 模块融入到网络不同位置对精度有较大的影响, 加入主干特征提取网络比加入 Neck 网络要多 5.6 个百分点。综合以上分析, 选择实验 4, 即在主干特征提取网络中融入 4 个 ECA 模块, 这样保证在参数量和网络层数尽可能少的

情况下, 最大限度发挥 ECA 模块对提升舰船特征关注的的能力, 舰船分类检测效果最佳。

4.3 与其他方法比较

为了验证 EB-YOLOv5s 的有效性, 利用 SSD、YOLOv3、YOLOv5s 这 3 种常用目标检测网络在 HRSC-4 数据集上进行对比实验。4 种网络参数在训练过程中尽可能保持一致, 其中训练次数均为 500 轮次, 初始学习率为 0.01。另外为加强 SSD 和 YOLOv3 网络的训练效果, 在训练过程中加载使用预

训练权重和冻结主干特征提取网络的方法加速网络收敛和训练效果, YOLOv5s 和所提方法未使用预训练模型, 以更好说明所提方法的优越性, 实验结果如表 3 所示。

表 3 不同检测方法的性能对比

Table 3 Performance comparison of different detection methods

| Method | mAP / % | t/s | Weight / MB |
|------------|---------|--------|-------------|
| YOLOv3 | 84.6 | 0.2870 | 235 |
| SSD | 89.7 | 1.622 | 92.1 |
| YOLOv5s | 83.9 | 0.1861 | 13.7 |
| EB-YOLOv5s | 89.2 | 0.2070 | 62.7 |

从表 3 可以看出: 相较于其他网络, 所提方法在检测速度、检测精度以及模型权重上相对有比较优秀的

表 4 平均精确度的对比

Table 4 Comparison for average accuracy

unit: %

| Method | mAP | AP ₁ (Aircraft_carrier) | AP ₂ (Warship) | AP ₃ (Civilian_ship) | AP ₄ (Submarine) |
|---------------|------|------------------------------------|---------------------------|---------------------------------|-----------------------------|
| YOLOv5s | 83.9 | 97.3 | 94.9 | 62.8 | 80.8 |
| YOLOv5s+SE | 85.9 | 97.8 | 96.0 | 65.3 | 84.7 |
| YOLOv5s+ECA | 87.4 | 99.2 | 94.4 | 69.1 | 86.8 |
| YOLOv5s+BIFPN | 86.5 | 94.0 | 94.3 | 66.9 | 90.8 |
| EB-YOLOv5s | 89.2 | 98.9 | 95.8 | 71.6 | 90.3 |

表 5 检测速度和网络复杂度的对比

Table 5 Comparison for detection speed and network complexity

| Method | t/s | Weight / MB | Layer | Parameters |
|---------------|--------|-------------|-------|------------|
| YOLOv5s | 0.1861 | 13.7 | 224 | 7062001 |
| YOLOv5s+SE | 0.2216 | 14.1 | 256 | 7237281 |
| YOLOv5s+ECA | 0.1998 | 13.7 | 240 | 7062013 |
| YOLOv5s+BIFPN | 0.1996 | 15.7 | 236 | 8128517 |
| EB-YOLOv5s | 0.2067 | 62.7 | 252 | 8128529 |

从表 4、表 5 可以看出: 在 YOLOv5s 网络中融入 4 个 ECA 模块共 16 层网络层数后, 参数量仅增加 12 个, 在模型大小、检测速度基本没有增加的基础上, 平均均值精度增加了 3.5 个百分点, 这验证了在主干特征提取网络中融入 ECA 模块能够显著提升网络对舰船特征的关注度, 以极低的计算成本提升网络对舰船的检测能力; 另外, 将 YOLOv5s 的 Neck 部分修改为 BIFPN 模块后, 可以看到模型大小仅增加 2 MB, 在检测时间基本没有增加的情况下平均均值精度增加了 2.6 个百分点, 潜艇和民船的 AP 值得到提升, 同样验证了 BIFPN 模块更好地对不同尺度舰船目标特征进行融合, 提升网络对不同尺度舰船的检测能力; ECA 模块的精度较 BIFPN 模块多 0.9 个百分点, 检测效果提升更为明显, 说明遥感图像中背景复杂导致的舰船特征不明显相较于舰船尺度变化问题更为突出; 同时,

表现; SSD 网络虽然检测精度最高, 但是检测速度较慢, 而所提网络的精度值与之相差不大的情况下, 平均检测时间减少 87.24%; YOLOv3 网络的检测速度相比于 SSD 较快, 但是检测精度相对较低, 模型较大, 无法满足实际应用需求。通过对比验证可以看出, 所提方法很好平衡了检测速度和精度, 与其他算法相比, 精度相差不大, 但是检测速度有很大的提升, 且网络模型简单, 能够满足实际部署需求。

4.4 消融实验

为了验证所提 ECA 模块和 BIFPN 模块引入的有效性, 验证 ECA 模块在提升舰船分类检测效果方面优于 SE 模块, 尝试在网络相同位置处引入相同数量 SE 模块, 进行 4 组实验进行对比。表 4 和表 5 记录了不同方法在 HRSC-4 数据集上进行消融实验的结果。

引入 SE 模块相比于引入 ECA 模块, 网络层数、参数量、模型权重均增加, 但是精度值却降低, 检测时间增加, 进一步从实验层面验证 ECA 模块优于 SE 模块, 具有轻量化的特点。同时加入两个模块后, 所提方法在检测时间基本没有增加的情况下, mAP 较原算法提升 5.3 个百分点, 对航母、军舰、民船、潜艇的 AP 值分别提升 1.6 个百分点、0.9 个百分点、8.8 个百分点、9.5 个百分点, 其中航母和军舰属于中大尺度目标, 较易检测, 提升效果不大, 潜艇和民船属于中小尺度目标, 提升效果较明显。

4.5 测试实验图片效果对比

图 5 展示 YOLOv3、SSD、YOLOv5s 以及加入各模块后检测的部分效果图。从图 5 可以看出: YOLOv3、SSD 以及 YOLOv5 检测的效果图片存在较为明显的漏检和置信度不高的情况, 而所提方法改善了此现象; 从 A 测试组中可以看到, 加入 ECA 模块后能够较好地检测出与背景相似的航母, 从 B 测试组中可以看到, 在未加入任何模块时, 对于尺度变化多样的图像, 漏检严重, 加入 BIFPN 模块后能够检测出尺度较小的潜艇, 证明 BIFPN 模块增强了高低尺度特征, 优化了特征融合, 很好地解决了遥感图像舰船检测中场景复杂、部分背景与舰船目标相似、舰船尺度变化多样导致的错漏检的问题。对于图 5, 可以从直观效果上验证 ECA 模块和 BIFPN 模块对遥感图像舰船算法的贡献度。

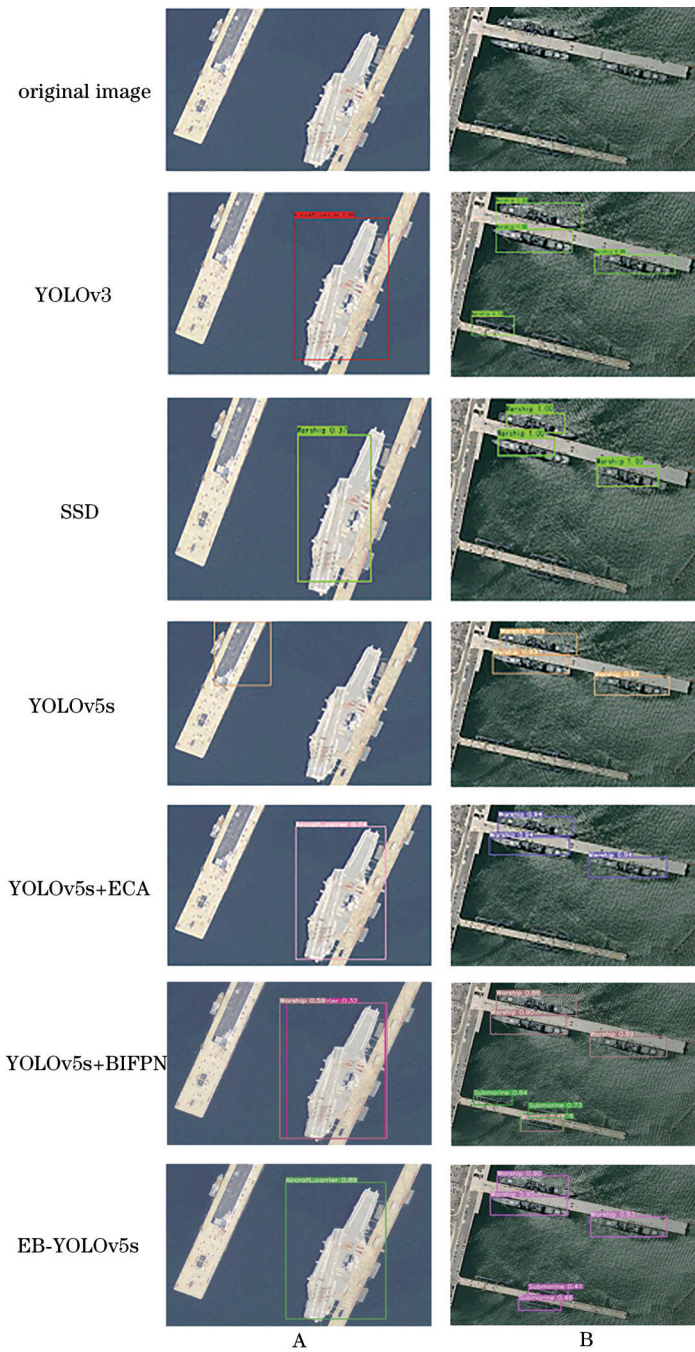


图 5 不同方法的检测效果

Fig. 5 Detection effect of different methods

5 结 论

提出了一种基于改进 YOLOv5s 的光学遥感图像检测分类方法。在主干特征提取网络阶段,在 4 个尺度特征提取层后融入 ECA 模块,使主干网络突出有用的特征,更加关注舰船目标特征;在特征融合阶段,引入 BIFPN 模块,原算法是简单连接的,改进之后进行加权连接,更好地融合每个尺度的特征。在遥感影像舰船数据集上进行测试,对所提方法的检测结果同 YOLOv5、YOLOv3、SSD 算法作对比。实验结果表明:改进后的网络可以准确且快速地检测出遥感图像中不同类别的舰船,相较于原 YOLOv5s 算法,错漏检

情况有了较大的改善;相较于传统的目标检测算法,所提方法无论是在检测速度,还是在网络模型大小以及检测精度上均表现良好,有效解决了遥感图像舰船检测中场景复杂、尺度变化多样引起的错漏检问题,能够在设备计算能力受限且对检测速度要求高的应用背景下,对舰船进行实时快速检测,实现遥感图像舰船检测在海洋搜救以及海上情报侦察预警等方面的应用。

虽然改进后的算法较原算法的性能有所提升,但本文未将舰船细化分类,仅将舰船分为四种类型,同时精度值还需进一步提升。在未来的工作中,一方面扩充舰船数据集,不断丰富舰船种类和数量,训练出能检测出舰船的种类甚至舰船型号模型,以满足实际应

用;另一方面,需要进一步提升算法的精确度,保证在满足一定检测速度需求下,不断提升对舰船的检测精度,实时、快速、准确地分类检测出各种类型舰船。

参 考 文 献

- [1] 李泽明,程亮,朱大明,等.基于深度学习和空间分析的港口识别[J].激光与光电子学进展,2021,58(20):2028002. Li Z M, Cheng L, Zhu D M, et al. Deep learning and spatial analysis based port detection[J]. Laser & Optoelectronics Progress, 2021, 58(20): 2028002.
- [2] 张财广,熊博莅,匡纲要.光学卫星遥感图像舰船目标检测综述[J].电波科学学报,2020,35(5):637-647. Zhang C G, Xiong B L, Kuang G Y. A survey of ship detection in optical satellite remote sensing images[J]. Chinese Journal of Radio Science, 2020, 35(5): 637-647.
- [3] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//2014 IEEE Conference on Computer Vision and Pattern Recognition, June 23-28, 2014, Columbus, OH, USA. New York: IEEE Press, 2014: 580-587.
- [4] Girshick R. Fast R-CNN[C]//2015 IEEE International Conference on Computer Vision, December 7-13, 2015, Santiago, Chile. New York: IEEE Press, 2015: 1440-1448.
- [5] 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.
- [6] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 779-788.
- [7] Redmon J, Farhadi A. YOLO9000: better, faster, stronger[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 6517-6525.
- [8] Liu W, Anguelov D, Erhan D, et al. SSD: single shot MultiBox detector[EB/OL]. (2015-12-08) [2021-03-02]. <https://arxiv.org/abs/1512.02325>.
- [9] Redmon J, Farhadi A. YOLOv3: an incremental improvement[EB/OL]. (2018-08-08) [2020-11-05]. <https://arxiv.org/abs/1804.02767>.
- [10] Bochkovskiy A, Wang C Y, Liao H Y M. YOLOv4: optimal speed and accuracy of object detection[EB/OL]. (2018-04-01) [2020-11-05]. <https://arxiv.org/abs/1804.00276>.
- [11] Ultralytics. YOLOv5[EB/OL]. (2020-06-03) [2021-04-15]. <https://github.com/ultralytics/yolov5>.
- [12] 汪鹏,辛雪静,王利琴,等.基于YOLOv3的光学遥感图像目标检测算法[J].激光与光电子学进展,2021,58(20):2028006. Wang P, Xin X J, Wang L Q, et al. Object detection algorithm of optical remote sensing images based on YOLOv3[J]. Laser & Optoelectronics Progress, 2021, 58(20): 2028006.
- [13] 徐志京,丁莹.自适应旋转区域生成网络的遥感图像舰船目标检测[J].激光与光电子学进展,2020,57(24):242805. Xu Z J, Ding Y. Ship object detection of remote sensing images based on adaptive rotation region proposal network[J]. Laser & Optoelectronics Progress, 2020, 57(24): 242805.
- [14] Liu S, Qi L, Qin H F, et al. Path aggregation network for instance segmentation[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 8759-8768.
- [15] Liu Z K, Wang H Z, Weng L B, et al. Ship rotated bounding box space for ship extraction from high-resolution optical satellite images with complex backgrounds [J]. IEEE Geoscience and Remote Sensing Letters, 2016, 13(8): 1074-1078.
- [16] Wang Q L, Wu B G, Zhu P F, et al. ECA-net: efficient channel attention for deep convolutional neural networks [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 11531-11539.
- [17] Tan M X, Pang R M, Le Q V. EfficientDet: scalable and efficient object detection[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 10778-10787.
- [18] Woo S, Park J, Lee J Y, et al. CBAM: convolutional block attention module[M]//Ferrari V, Hebert M, Sminchisescu C, et al. Computer vision-ECCV 2018. Lecture notes in computer science. Cham: Springer, 2018, 11211: 3-19.
- [19] Hu J, Shen L, Albanie S, et al. Squeeze-and-excitation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(8): 2011-2023.
- [20] 蒋寰游.基于YOLOV5的无人机航拍输电线路绝缘子多缺陷检测[D].广州:广东工业大学,2021. Jiang H Y. Multi-defect detection of insulators in transmission lines for UAV aerial photography based on YOLOV5[D]. Guangzhou: Guangdong University of Technology, 2021.
- [21] Lin T Y, Dollár P, Girshick R, et al. Feature pyramid networks for object detection[C]//The IEEE Conference on Computer Vision and Pattern Recognition(CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 5936-5944.
- [22] 郝帅,杨磊,马旭,等.基于注意力机制与跨尺度特征融合的YOLOv5输电线路故障检测[J/OL].中国电机工程学报: 1-12[2022-02-09]. <http://kns.cnki.net/kcms/detail/11.2107.tm.20220126.1718.008.html>.
- [23] Hao S, Yang L, Ma X, et al. YOLOv5 transmission line fault detection based on attention mechanism and cross-scale feature fusion[J/OL]. Proceedings of the CSEE: 1-12[2022-02-09]. <http://kns.cnki.net/kcms/detail/11.2107.tm.20220126.1718.008.html>.
- [23] 李维刚,杨潮,蒋林,等.基于改进YOLOv4算法的室内场景目标检测[J].激光与光电子学进展,2022,59(18):1815003. Li W G, Yang C, Jiang L, et al. Indoor scene object detection based on improved YOLOv4 algorithm[J]. Laser & Optoelectronics Progress, 2022, 59(18): 1815003.