

基于改进 YOLOv5 的船舶目标检测算法

丘锐聪^{1,2}, 周海峰^{1,2}, 陈颖^{1,2}, 张兴杰³, 黄金满⁴, 翁卫征⁵

- (1. 集美大学轮机工程学院, 福建 厦门 361021; 2. 福建省船舶与海洋工程重点实验室 (集美大学), 福建 厦门 361021;
3. 集美大学航海学院, 福建 厦门 361021; 4. 厦门安麦信自动化科技有限公司, 福建 厦门 361021;
5. 厦门三丰鑫科技有限公司, 福建 厦门 361001)

[摘要] 为了解决船舶目标因宽高比较大而导致在特征提取过程中容易丢失细节信息、提取较多无关信息, 以及小型船舶在图像中区域占比较小导致检测困难等问题, 本文提出 ShipsYOLOv5 船舶目标检测算法。首先, 利用可变形卷积特性设计 C3_DCN 模块并引入主干特征提取网络, 通过增加采样偏移量来适应船舶目标形状特点, 抑制无关背景信息影响, 提升网络特征提取能力; 然后, 引入基于 Wasserstein 距离的度量方法改进边界框损失函数, 提升模型对小型船舶目标的检测性能; 最后, 用 Seaships 船舶数据集进行验证实验, 结果表明, 本文提出的 ShipsYOLOv5 算法相较于基准模型在精度、召回率和 mAP@0.5 上分别有 1.9%、1.9% 和 2.3% 的提升, 且分别达到了 98.3%、99.0% 和 99.1%, 能满足船舶目标检测性能要求。

[关键词] 船舶目标检测; YOLOv5s; 可变形卷积; 改进损失函数

[中图分类号] TP 391.4

Ship Target Detection Algorithm Based on Improved YOLOv5

QIU Ruicong^{1,2}, ZHOU Haifeng^{1,2}, CHEN Ying^{1,2}, ZHANG Xingjie³, HUANG Jinman⁴, WENG Weizheng⁵

(1. School of Marine Engineering, Jimei University, Xiamen 361021, China;

2. Key Laboratory of Shipping and Ocean Engineering of Fujian Province (Jimei University), Xiamen 361021, China;

3. School of Navigation, Jimei University, Xiamen 361021, China;

4. Xiamen Anmaixin Automation Technology Co., Ltd., Xiamen 361021, China;

5. Xiamen Sanfengxin Technology Co., Ltd., Xiamen 361001, China)

Abstract: In order to solve the problems of losing detail/extracting irrelevant information caused by relatively high width to height ratios during detection of target ships, and the detection difficulties caused by small ships occupying a relatively small area in the image, this paper proposes a detection algorithm based on shipsYOLOv5. First of all, a C3_DCN module is designed by using the deformable convolution feature and the key feature extraction network is introduced to adapt to the shape characteristics of the target ship and suppress the influence of irrelevant background information as well as to improve the network feature extraction capability, by adding sampling offset. Secondly, the loss function is improved by using a metric method

[收稿日期] 2023-06-02

[基金项目] 国家自然科学基金项目 (51179074); 福建省自然科学基金项目 (2021J01839); 集美大学安麦信产学研项目 (S20127)

[通信作者] 周海峰 (1970—), 博士, 教授, 主要从事智能信息处理、光机电一体化和仿生机理以及节能等研究。E-mail: zhufeng216@163.com

based on Wasserstein distance to improve the bounding box loss function, thereby enhancing the model's detection performance for small vessel targets. In this paper, Seaships dataset is used to verify the above improved method. The experimental results show that compared with the benchmark model, the accuracy, recall rate and mAP@0.5 of the proposed ShipsYOLOv5 algorithm have improved by 1.9%, 1.9% and 2.3% respectively, reaching 98.3%, 99.0% and 99.1%, respectively. It can meet the performance requirements of ship target detection.

Keywords: object detection of ship; YOLOv5s; deformable convolution; improved loss function

0 引言

船舶目标检测是海上智能化航行的关键，其对模型的识别精度有较高的要求。基于深度学习的目标检测算法用于海上航行船舶的目标检测已成为交通运输领域中一个极受欢迎的热点和应用方向。当前目标检测算法主要分为两类：一类是以 YOLO (you only look once) 系列^[1]、SSD (single shot multibox detector)^[2]为代表的单阶段目标检测算法；另一类是以 R-CNN (regions with convolutional neural network)^[3]、Faster R-CNN (faster regions with convolutional neural network)^[4]为代表的双阶段目标检测算法。其中，单阶段目标检测算法将检测任务作为一个简单的回归问题，将输入的图像经过卷积神经网络提取特征后利用处理回归问题的方法解决目标的框选，因此，在保证足够识别精度的前提下，单阶段目标检测算法比双阶段目标检测算法推理效率更高、识别速度更快、推理时间更少，还能满足以视频为输入源的实时目标检测任务需求。

Chen 等^[5]在 YOLOv3 基础上添加注意力机制，于特征融合部分构建特征增强模块，不仅提升了模型的特征提取能力，还增强了特征层之间的关联度。周慧等^[6]从 FPN 目标检测算法入手，利用可变形卷积和通道注意力机制来更好地确定目标采样位置以及捕获网络中不同通道特征图之间依赖关系，降低模型对合成孔径雷达 (SAR) 船舶图像误检率，提升检测精度。Li 等^[7]为提升船舶定位能力，提出新双分支回归网络，经过数据集验证，该网络的船舶定位能力显著。赵玉蓉等^[8]对 YOLOv4 进行改进，提出的 YOLO-Marine 模型通过引入注意力机制和 K-Means++ 聚类获得初始锚框，提高了船舶目标检测精度。王治国等^[9]从输入、主干网络、颈部结构、损失函数四个方面改进 YOLOv4 算法，验证了检测水面目标的可行性。Han 等^[10]改进 YOLOv4 的空间金字塔池化模块和特征金字塔，引入空洞卷积和注意力机制，不仅提升了特征提取能力，还加快了推理速度。周旗开等^[11]在 YOLOv5s 模型的主干特征提取网络中使用一种轻量、高效的通道注意力，并将获得的特征图输入加权双向特征金字塔结构进行特征优化融合，使得改进后的模型检测速度更快，检测精度更高。Chen 等^[12]为准确而快速地检测船舶，利用旋转解耦头、注意力机制和双向特征网络改进 YOLOv5，改进方法能满足实时船舶检测的需求。

虽然以上各改进算法依据船舶特殊的作业环境将通用算法做相应优化，但仍存在许多不足。由于图像中船舶目标的宽高比较大，所以使用标准卷积的主干特征提取网络在进行特征提取时容易丢失较多细节信息和提取过多无关特征信息；而岸上楼房、基建设施等背景信息对船舶目标检测也有着一定程度的信息干扰，导致模型检测效果较差；另外，由于小型船舶目标在图像中区域占比小，因而模型对小型船舶目标的检测能力不足，检测精度差。针对上述问题，本文提出一种基于 YOLOv5 的船舶目标检测改进算法——ShipsYOLOv5。

1 ShipsYOLOv5 算法

本文在 YOLOv5s 基础上将可变形卷积引入主干特征提取网络中的 C3 模块，构造 C3_DCN 模块，更好地适应船舶目标形状变化，减轻无关信息对检测任务的影响，提升特征提取能力；另外，为提升模型对小型船舶目标的检测性能，引入一种基于 Wasserstein 距离的小目标检测评

估方法与 CIoU 一起作为评估指标, 改进损失函数, 在保证模型训练收敛速度的同时, 提升模型对小目标的检测性能。ShipsYOLOv5 网络结构如图 1 所示。

1.1 构造 C3_DCN 模块

传统卷积神经网络中, 卷积层的卷积运算由于没有二维几何变形机制, 其卷积核只能对特征图进行固定位置的特征采样和学习。标准卷积中规则的网格点采样导致其对于未知的变化适应性差, 存在一定局限性, 泛化能力不强, 以至于在检测宽高比较大的船舶目标时容易丢失更多船舶目标特征信息。然而, 可变形卷积能在原来标准卷积采样位置添加偏移量^[13], 因而能根据实际情况来调整自身的形状, 不再局限于固定采样方式, 在采样时可以更好地贴近检测目标的形状和尺寸, 更好地适应检测环境变化, 从而抑制图像中无关内容的影响, 提升特征获取能力。其实现公式为:

$$\sigma = \{(-1, -1), (-1, 0), \cdots, (0, 1), (1, 1)\}, \tag{1}$$

$$y(P_0) = \sum_{P_n \in \sigma} w(P_n) \cdot x(P_0 + P_n + \Delta P_n), \tag{2}$$

$$x(P) = \sum_q G(q, P) \cdot x(q). \tag{3}$$

公式 (1) 表示使用规则网格 σ 在输入特征图 x 上进行采样。特征图 y 中的每个位置由公式 (2) 中 $y(P_0)$ 表示, 其中 P_n 枚举 σ 中的所有采样位置, 并通过在规则网格 σ 中对每个采样位置增加偏移量 ΔP_n , 形成不规则采样位置, 构成可变形卷积。由于公式 (2) 中的 ΔP_n 通常为小数, 所以使用双线性插值实现公式 (3), 其中 P 表示任意位置, q 枚举了特征图 x 上的所有积分空间位置, $G(q, P)$ 表示双线性插值核。标准卷积与可变形卷积采样对比示意图如图 2 所示。




图2 标准卷积与可变形卷积

Fig.2 Standard convolution and deformable convolution

因此, 为减少因船舶目标宽高比较大而带来的影响, ShipsYOLOv5 将可变形卷积网络引入主干网络中的 C3 模块, 替换其 Bottleneck 模块中的 3×3 卷积, 构建 C3_DCN 模块, 并替换原来 YOLOv5s

主干网络中相应位置的 C3 模块, 形成新主干特征提取网络。C3_DCN 模块结构如图 3 所示。

在保留残差结构的 C3_DCN 模块中, 输入特征从残差主干和残差边分别经过卷积核大小为 1×1 的 CBS 模块对通道数进行压缩处理获得特征图 f_1 和 f_2 ; 进入残差主干的输入特征 f_2 被可变形卷积进行处理得到特征图 f_3 ; 另一路作为残差边, 经过 CBS 模块处理后与残差主干连接得到特征图 f_4 ; 再经过卷积核大小为 1×1 的 CBS 模块处理后获得特征图 f_5 ; 最后 f_5 作为该模块的最终输出进入下一环节的特征提取。

1.2 改进损失函数

小目标检测是目标检测中具有难度问题, 本文所使用的 Seaships 船舶数据集中也存在小型船舶目标。在复杂的船舶作业环境中, 小型船舶目标在图像中区域占比少, 在与大船接近或相互遮挡情况下易被忽略; 另外, 损失函数作为预测结果与真实标注信息之间距离的度量, 若两者越接近, 则损失函数值越小。由此看来, 损失函数对模型检测性能影响较大。然而, YOLOv5s 的边界框损失函数 CIOU_Loss 对小目标位置偏差十分敏感, 严重降低小型船舶的检测性能。

针对上述问题, 本文设计新边界框损失函数, 用基于 Wasserstein 距离的小目标度量方法 (normalized wasserstein distance, NWD) 与 CIOU_Loss 共同计算模型边界框损失, 而置信度损失和分类损失仍选用 BCE_Loss。

首先用边界框像素权值呈现中心点最高且向边界依次递减的二维高斯分布对边界框进行建模^[14]。该分布概率密度函数表达式为:

$$f(x|\mu, \Sigma) = \frac{\exp(-\frac{1}{2}(x-\mu)^T \Sigma^{-1}(x-\mu))}{2\pi |\Sigma|^{\frac{1}{2}}}. \quad (4)$$

其中 x 、 μ 和 Σ 分别表示像素点坐标、平均矢量和 Gaussian 分布的协方差矩阵。当 $(x-\mu)^T \Sigma^{-1}(x-\mu) = 1$ 时, 可将边界框建模为一个二维高斯分布 $N(\mu, \Sigma)$ 。

接着, 预测边界框和真实边界框的二维高斯分布建模结果分别为: $\mu_a = N(m_a, \Sigma_a)$ 和 $\mu_b = N(m_b, \Sigma_b)$, 再将两者之间的二阶 Wasserstein 距离定义为: $W_2^2(\mu_a, \mu_b) = \|m_a - m_b\|_2^2 + \|\Sigma_a^{\frac{1}{2}} - \Sigma_b^{\frac{1}{2}}\|_F^2$ 。

进行指数形式归一化后得到基于 Wasserstein 距离度量: $D(N_a, N_b) = \exp(-\frac{\sqrt{W_2^2(N_a, N_b)}}{C})$ 。最后, 将距离度量 D 设为损失函数, 其表达式为: $l_{\text{NWD}} = 1 - D(N_a, N_b)$ 。因此, 本文的新边界框损失函数表达式为:

$$l_{\text{CIOU+NWD}} = 0.5 \cdot l_{\text{CIOU}} + 0.5 \cdot l_{\text{NWD}} = (0.5 \cdot \sum_{i=0}^{S^2} \sum_{j=0}^B I_{i,j}^{\text{obj}} [1 - R_{\text{IoU}} + \frac{\rho^2(b, b^{\text{gt}})}{c^2} + \alpha\nu] + 0.5 \cdot [1 - D(N_a, N_b)]). \quad (5)$$

置信度损失 l_{obj} 和分类损失 l_{cls} 使用 BCE_Loss 计算, 具体表达式如下:

$$l_{\text{obj}} = - \sum_{i=0}^{S^2} \sum_{j=0}^B I_{i,j}^{\text{obj}} [\hat{C}_i \ln(C_i) + (1 - \hat{C}_i) \ln(1 - C_i)] - \lambda_{\text{noobj}} \sum_{i=0}^{S^2} \sum_{j=0}^B I_{i,j}^{\text{noobj}} [\hat{C}_i \ln(C_i) + (1 - \hat{C}_i) \ln(1 - C_i)], \quad (6)$$

$$l_{\text{cls}} = - \sum_{i=0}^{S^2} \sum_{j=0}^B I_{i,j}^{\text{obj}} \sum_{c=0}^C [P_i(c) \ln(P_i(c)) + (1 - P_i(c)) \ln(P_i(c))]. \quad (7)$$




图 3 C3 与 C3_DCN 结构图

Fig.3 C3 and C3_DCN structures

船舶监控图像。该数据集由 6 类船舶组成，分别为：矿船（ore carrier）、普通货船（general cargo ship）、散货船（bulk cargo carrier）、集装箱船（container ship）、渔船（fishing boat）和客船（passenger ship）。数据集中所有的图片都是 1920 px × 1080 px、RGB 三通道可见光图像^[16]。开源的 7000 张图片内容较为丰富，包括了不同背景、不同天气、不同视角、不同时间下的水上航行中的船舶图片。本文先将训练集、验证集的总和与测试集按 9:1 比例进行划分，再在训练集、验证集总和中将训练集与验证集也按 9:1 比例进行划分，于是训练集共有 5670 张图片、验证集共有 630 张图片、测试集共有 700 张图片。

2.3 评价指标

为评估改进后算法模型的性能，本文选取了精度 P 、召回率 R 、平均精度均值 M （mean average precision, mAP）和浮点运算次数（giga floating-point operations per second, GFLOPs）为评价指标。精度表示正确预测的样本占预测为阳性样本的比例；召回率表示正确预测的阳性样本占所有阳性样本的比例。mAP 为平均精度（average precision, AP）的平均值，数值越高，其模型的检测效果越好； P_{AP} 是以精度作为纵坐标、召回率作为横坐标与所构成的 P - R 曲线围成的面积。各评价指标表达式如下：

$$P = 100\% \times P_{TP} / (P_{TP} + P_{FP}),$$
$$R = 100\% \times P_{TP} / (P_{TP} + P_{FN}),$$
$$P_{AP} = \int_0^1 P(r) dr,$$
$$M = \frac{1}{n} \sum_{i=1}^n P_{AP}(i)。$$

其中： P_{TP} 为被正确检测的阳性样本数量； P_{FP} 为被误检的阳性样本数量； P_{FN} 则代表未被模型检测到的阴性样本数量； n 为数据集中船舶类别数量，本文数据集共有 6 类船舶，即 $n = 6$ 。

2.4 结果分析

为比较不同改进策略改进后的模型与原模型之间的优劣，本文设计了不同改进策略改进的算法模型并做对比实验。

2.4.1 C3_DCN 模块实验分析

主干特征提取网络作为模型对输入图像进行特征提取并学习的主要部分，不同于颈部网络的多尺度特征融合处理，其特征提取效率极大程度上决定了整个网络的特征学习质量。因此，本文针对基准模型的主干特征提取网络作出改进，探究改进后的 C3_DCN 模块在主干中发挥作用的最优位置，以及证明本文所用可变形卷积在网络模型中的有效性。

本文将 YOLOv5s 模型主干网络中 C3 模块残差主干上 BottleNeck 模块中的 3×3 标准卷积替换成 3×3 可变形卷积，形成 BottleNeck_DCN 模块并替换 BottleNeck 模块，构建 C3_DCN 模块，并通过实验结果探究 C3_DCN 在主干网络中最优使用位置和数量组合。表 1 为在 Seaships 船舶数据集上进行对比的实验结果。

表 1 C3_DCN 模块实验对比
Tab. 1 Experimental comparison of C3_DCN module

算法模型	参数量/ 10^6	浮点运算次数/ 10^6	精度/%	召回率/%	mAP@ 0.5/%
YOLOv5s	7.03	16.0	96.4	97.1	96.8
YOLOv5s_DCN-1	7.23	13.8	96.8(↑0.4)	97.6(↑0.5)	98.7(↑1.9)
YOLOv5s_DCN-2	7.21	13.7	97.6(↑1.2)	97.7(↑0.6)	99.0(↑2.2)
YOLOv5s_DCN-3	7.18	14.3	97.5(↑1.1)	96.8(↓0.3)	98.9(↑2.1)
YOLOv5s_DCN-4	7.09	15.4	97.7(↑1.3)	96.7(↓0.4)	98.8(↑2.0)

表 1 中 YOLOv5s_DCN- x 表示将原 YOLOv5s 模型主干特征提取网络中的所有 C3 模块做相应替换。其中: YOLOv5s_DCN-1 表示将原主干网络的四个 C3 模块全部替换为 C3_DCN 模块; YOLOv5s_DCN-2 表示将原主干网络第二到第四个 C3 模块替换为 C3_DCN 模块; YOLOv5s_DCN-3 表示将原主干网络第三到第四个 C3 模块替换为 C3_DCN 模块; YOLOv5s_DCN-4 表示将原主干网络第四个 C3 模块, 即最后的 C3 模块替换为 C3_DCN 模块。通过以上实验结果表明, 除了 YOLOv5s_DCN-3 和 YOLOv5s_DCN-4 对比原 YOLOv5s 模型, 其召回率略有下降外, 引入可变形卷积后新构建的 C3_DCN 模块在模型主干特征提取网络的不同位置使用, 其模型的目标检测精度都有不同程度的提升, 证明了 C3_DCN 模块的有效性。另外, 实验中所有改进模型的计算量比原 YOLOv5s 模型都有所减少, 具有一定程度的轻量化。实验中 YOLOv5s_DCN-2 模型的参数量略有增长 (增长 0.18×10^6); 但其 GFLOPs 计算次数降低了 2.3; 精度、召回率和 mAP@0.5 分别达到 97.6%、97.7% 和 99.0%, 相比于原 YOLOv5s 模型分别增长了 1.2%、0.6% 和 2.2%。由上述实验可知, 本文提出的 C3_DCN 模块在主干特征提取网络的中层至后层使用该模块效果较好, 其原因可能是中、后层特征包含更丰富的语义信息, 更利于可变形卷积确定图像中目标位置, 提取更准确的位置信息和语义信息。


2.4.2 改进损失函数实验分析

为验证改进损失函数是否提升模型对小型目标船舶的检测性能, 本文使用 NWD 与 CIoU 共同评估模型检测结果, 计算训练边界框损失。本文将改进损失函数分别作为上述改进模型和原 YOLOv5s 模型的损失函数, 并在 Seaships 数据集上做对比实验, 实验结果如表 2 所示。

表 2 改进损失函数验证实验
Tab. 2 Improved loss function verification experiment

算法模型	参数量/ 10^6	浮点运算次数/ 10^6	精度/%	召回率/%	mAP@0.5/%
YOLOv5s(CIoU)	7.03	16.0	96.4	97.1	96.8
YOLOv5s + NWD	7.03	16.0	97.0(↑0.6)	97.6(↑0.5)	98.3(↑1.5)
YOLOv5s_DCN-1 + NWD	7.23	13.8	97.1(↑0.7)	97.8(↑0.7)	99.0(↑2.2)
YOLOv5s_DCN-2 + NWD	7.21	13.7	98.3(↑1.9)	99.0(↑1.9)	99.1(↑2.3)
YOLOv5s_DCN-3 + NWD	7.18	14.3	97.6(↑1.2)	97.8(↑0.7)	98.9(↑2.1)
YOLOv5s_DCN-4 + NWD	7.09	15.4	97.9(↑1.5)	97.8(↑0.7)	98.8(↑2.0)

表 2 中 YOLOv5s_DCN- x + NWD 表示模型训练时使用改进损失函数进行模型损失计算。实验结果表明, 本文改进的损失函数作为原模型和改进模型的损失函数, 对 Seaships 船舶数据集中的渔船和客船这两类小型目标船舶的检测性能都有所提升。图 5 为模型训练损失变化曲线对比图。



a) YOLOv5s 训练损失曲线





图 5 模型训练损失变化曲线

Fig.5 Change curve of model training loss

使用改进损失函数后，损失曲线收敛迅速且稳定，减少了部分损失。同时，在不改变模型参数量和计算量的前提下，其精度、召回率和 mAP@ 0.5 均有所提升，其中 YOLOv5s_DCN-2 + NWD 模型的性能提升较为突出，因此将其作为本文所提出的 ShipsYOLOv5 算法模型。

2. 4. 3 对比实验

为进一步评估本改进算法模型的检测性能，将 ShipsYOLOv5 算法模型与 YOLOv5n、YOLOv4^[17]、YOLOv4-tiny 和 YOLOv3^[18]等主流目标检测算法在 Seaships 数据集上进行检测性能对比，所有实验在相同的训练参数下完成。对比实验结果见表 3。

表 3 ShipsYOLOv5 与经典目标检测算法对比实验结果

Tab. 3 Experimental results of comparison between ShipsYOLOv5 and classical target detection algorithm

算法模型	参数量/ 10^6	浮点运算次数/ 10^6	精度/%	召回率/%	mAP@ 0. 5/%
YOLOv5s	7. 03	16. 00	96. 4	97. 1	96. 8
YOLOv5n	1. 77	4. 20	96. 1	97. 2	96. 4
YOLOv4	63. 97	59. 99	96. 3	93. 3	96. 9
YOLOv4-tiny	5. 89	6. 84	94. 5	95. 1	97. 2
YOLOv3	61. 55	65. 63	96. 5	94. 1	97. 6
SSD	26. 28	62. 79	96. 8	96. 6	97. 2
Faster R-CNN	137. 09	370. 41	97. 1	96. 9	97. 6
ShipYOLOv5	7. 21	13. 70	98. 3	99. 0	99. 1

表 3 实验结果表明，相较于几个主流目标检测算法，本文提出的 ShipsYOLOv5 在 Seaships 数据集上实验精度达到 98. 3%、召回率达到 99. 0%、mAP@ 0. 5 达到 99. 1% ，且模型参数量、计算量都低

于大部分算法模型, 证明本文提出的 ShipsYOLOv5 与主流目标检测算法模型相比更具优势。图 6 为 YOLOv5s 与改进模型对比实验可视化结果。




图 6 YOLOv5s 与改进模型对比实验结果可视化

Fig.6 Visualization of experimental results compared with YOLOv5s and improved model

从图 6 中可看出, ShipsYOLOv5 算法模型不仅提升了对宽高比较大的船舶目标的检测性能, 也同时具备更好的小型船舶目标检测能力。

综上所述, 本 ShipsYOLOv5 算法模型查全率、查准率和识别精度相对更高, 检测性能更优。

3 结论

本文针对船舶目标宽高比较大而影响船舶目标检测效率和小型船舶目标检测困难等问题, 通过改进模型结构, 提出一种基于改进 YOLOv5s 的船舶目标检测算法。首先, 依据可变形卷积特性, 构建新特征提取模块并替换基准模型主干特征提取网络中的特定模块, 使其特征提取注意力更好地聚焦在船舶目标上, 从而抑制无关信息的获取, 提升特征提取能力。其次, 改进了边界框损失函数并引入 NWD, 增强了模型对小型船舶目标的检测能力。由 Seaships 船舶数据集上实验的对比结果可总结出, 本文的 ShipsYOLOv5 算法模型相较于基准模型在检测精度上提高了 1.9%, 召回率提高了 1.9%, 以及 mAP@0.5 提高了 2.3%, 不仅优于基准模型, 而且相较于许多主流的目标检测算法更有优势。由于本文所使用的数据集里船舶类别较少, 所以在下一步的工作中, 将使用具有更多船舶类别的数据集进行训练, 增强模型泛化能力, 并研究如何使模型在保证检测性能的同时实现模型轻量化, 为日后模型嵌入硬件而准备。

[参考文献]

- [1] 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(CVPR). Las Vegas, NV, USA: IEEE, 2016: 779-788.
- [2] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector[C]//2016 European Conference on Computer Vision. Cham: Springer, 2016: 21-37.
- [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. Columbus, OH, USA: IEEE, 2014: 580-587.
- [4] 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.
- [5] CHEN D, SUN S, LEI Z, et al. Ship target detection algorithm based on improved YOLOv3 for maritime image[J]. Journal of Advanced Transportation, 2021(8): 9440212(1-11).
- [6] 周慧, 李迎秋, 陈澎, 等. 基于改进 FPN 的复杂场景下 SAR 图像船舶目标检测[J]. 大连海事大学学报, 2022, 48(4): 76-83.
- [7] LI L, ZHOU Z, WANG B. A novel CNN-based method for accurate ship detection in HR optical remote sensing images via rotated bounding box[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 59(1): 686-699.
- [8] 赵玉蓉, 郭会明, 焦函, 等. 融合混合域注意力的 YOLOv4 在船舶检测中的应用[J]. 计算机与现代化, 2021(9): 75-82.
- [9] 王治国, 王勇, 谭笑, 等. 基于 YOLOv4 的水面目标快速检测[J]. 舰船电子工程, 2022, 42(4): 110-113.
- [10] HAN X, ZHAO L N, NING Y, et al. ShipYOLO: an enhanced model for ship detection[J]. Journal of Advanced Transportation, 2021: 1060182.
- [11] 周旗开, 张伟, 李东锦, 等. 基于改进 YOLOv5s 的光学遥感图像舰船分类检测方法[J]. 激光与光电子学进展, 2022, 59(16): 476-483.
- [12] CHEN X, WU H, HAN B, et al. Orientation-aware ship detection via a rotation feature decoupling supported deep learning approach[J]. Engineering Applications of Artificial Intelligence, 2023, 125: 106686.
- [13] ZHU X Z, HU H, LIN S, et al. Deformable Convnets v2: more deformable, better results[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR). Long Beach, CA, USA: IEEE, 2019: 9308-9316.
- [14] XU C, WANG J W, YANG W, et al. Detecting tiny objects in aerial images: a normalized Wasserstein distance and a new benchmark[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2022, 190: 79-93.
- [15] SHAO Z, WU W, WANG Z, et al. Seaships: a large-scale precisely annotated dataset for ship detection[J]. IEEE Transactions on Multimedia, 2018, 20(10): 2593-2604.
- [16] 萧箏, 王继业, 夏叶亮. 基于 MSAM-YOLOv5 的内河航道船舶识别方法[J]. 华中科技大学学报(自然科学版), 2023, 51(5): 67-73.
- [17] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: optimal speed and accuracy of object detection[C]//IEEE conference on Computer Vision and Pattern Recognition. ArXiv:2020, 2004. 10934. DOI:10.48550/arXiv.2004.10934.
- [18] REDMON J, FARHADI A. YOLOv3: an incremental improvement[C]//IEEE conference on Computer Vision and Pattern Recognition. arXiv:2018, 1804. 02767. DOI:10.48550/arXiv.1804.02767.

(责任编辑 朱雪莲 英文审校 周云龙)