

基于改进FCOS的遥感图像舰船目标检测

陈天鹏, 胡建文

引用本文

陈天鹏, 胡建文. 基于改进FCOS的遥感图像舰船目标检测[J]. 计算机科学, 2024, 51(6A): 230700166-7.

CHEN Tianpeng, HU Jianwen. Ships Detection in Remote Sensing Images Based on Improved FCOS [J]. Computer Science, 2024, 51(6A): 230700166-7.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[面向嵌入式平台的光学遥感图像舰船检测识别](#)

Ship Detection and Recognition of Optical Remote Sensing Images for Embedded Platform
计算机科学, 2024, 51(6A): 230700117-7. <https://doi.org/10.11896/jsjcx.230700117>

[结合多尺度卷积块与密集卷积块的遥感图像融合](#)

Remote Sensing Image Fusion Combining Multi-scale Convolution Blocks and Dense Convolution Blocks
计算机科学, 2024, 51(6A): 230400110-6. <https://doi.org/10.11896/jsjcx.230400110>

[多尺度特征融合的遥感图像目标检测方法](#)

Object Detection Method with Multi-scale Feature Fusion for Remote Sensing Images
计算机科学, 2024, 51(3): 165-173. <https://doi.org/10.11896/jsjcx.230200030>

[基于递归门控卷积的遥感图像超分辨率研究](#)

Recursive Gated Convolution Based Super-resolution Network for Remote Sensing Images
计算机科学, 2024, 51(2): 205-216. <https://doi.org/10.11896/jsjcx.230800017>

[基于生成对抗网络的遥感图像锐化方法](#)

Remote Sensing Image Pan-sharpening Method Based on Generative Adversarial Network
计算机科学, 2023, 50(8): 133-141. <https://doi.org/10.11896/jsjcx.220600065>

基于改进 FCOS 的遥感图像舰船目标检测

陈天鹏 胡建文

长沙理工大学电气与信息工程学院 长沙 410114

(1183108098@qq.com)

摘要 由于遥感图像中舰船目标方向任意,基于深度学习的通用目标检测算法采用水平框,在检测舰船时易框选大量背景,检测效果欠佳。文中提出一种改进全卷积一阶段目标检测网络(FCOS)的遥感图像舰船目标检测算法,以 FCOS 为基线,在检测头部分增加一条偏移回归分支,通过偏移水平框的上边中点和右边中点,产生旋转框。舰船目标通常具有较大的长宽比,预测框与真实框之间的角度偏差对交并比的影响较大,进而影响模型的检测精度。针对该问题,在计算偏移损失时引入与舰船目标长宽比有关的加权因子,使得具有较大长宽比的目标获得较大的偏移损失。在 HRSC2016 数据集上的实验结果表明,所提算法的平均精确度达到 89.00%,检测速度达到 19.8FPS,相比同类型的无锚框算法,其在检测速度和检测精度上均表现优秀。

关键词: 遥感图像;舰船目标检测;FCOS;无锚框算法;偏移分支

中图分类号 TP391

Ships Detection in Remote Sensing Images Based on Improved FCOS

CHEN Tianpeng and HU Jianwen

School of Electrical and Information Engineering, Changsha University of Science and Technology, Changsha 410114, China

Abstract Ships in remote sensing images are arranged in arbitrary directions. The general target detection algorithm based on deep learning use horizontal bounding box to locate object, which will select a large number of backgrounds when detecting ships. The ships detection performance based on general object detection method is not good. An improved ships detection algorithm based on fully convolutional one-stage(FCOS) object detection network is proposed. Taking FCOS as the baseline, an offset regression branch is added to detection head, and a rotating bounding box is generated by shifting the upper midpoint and the right midpoint of the horizontal bounding box. The ships usually have high aspect ratio, and the angle deviation between the predicted bounding box and the real bounding box has a great influence on the intersection over union(IoU), which damages the detection accuracy of the model. In order to solve this problem, a weighting factor related to the aspect ratio of ships is introduced to calculate the offset loss, so that the target with a large aspect ratio can obtain relatively large offset loss. The proposed method and several mainstream rotating target detection algorithms are tested on HRSC2016 dataset. The results show that the average accuracy of the proposed method is 89.00% and the detection speed is 19.8FPS. Compared with the same type of algorithms without anchor, the proposed method has superior detection speed and accuracy.

Keywords Remote sensing image, Ships detection, FCOS, Anchor-free algorithm, Offset branch

1 引言

随着遥感技术和成像传感器技术的发展,遥感图像的质量不断提升,目标物体在图像中变得更加清晰,基于遥感图像的目标检测引起了大量学者的广泛关注^[1]。舰船目标定位和监测在海洋交通运输、敌情勘察、海洋开发等领域扮演着重要角色,是当前遥感图像目标检测领域的研究热点。因此,遥感图像舰船目标检测具有重要的研究意义和应用前景^[2]。

不同于自然图像,遥感图像背景复杂,舰船目标在遥感图像中呈现出方向任意、尺度差异大等特点。通用的水平框目

标检测算法由于利用水平框对目标进行框选,对舰船目标进行检测时,会存在框选不精确、目标框重叠等问题^[3]。舰船目标通常具有较大的长宽比,呈细长形,进一步影响检测精度。

随着深度学习在目标检测任务中的广泛应用以及大量高分辨率遥感图像的支持,遥感图像舰船目标检测受到广泛关注。众多学者对通用目标检测算法进行改进,并将其应用于遥感图像舰船目标检测。文献[4]在二阶段目标检测算法的区域生成网络中引入旋转锚框,并结合密集连接的特征金字塔,能够较好地适应方向任意分布的舰船目标。文献[5]提出一种基于特征和区域定位增强的舰船检测算法,设计一种极

基金项目:国家自然科学基金面上项目(62271087);湖南省自然科学基金(2021JJ40609);湖南省教育厅科研项目(21B0330);长沙市自然科学基金(kq2208403)

This work was supported by the National Natural Science Foundation of China(62271087), Natural Science Foundation of Hunan Province, China (2021JJ40609), Research Project of Hunan Provincial Department of Education (21B0330) and Natural Science Foundation of Changsha (kq2208403).

通信作者:胡建文(117780631@qq.com)

化双重注意力网络模块,在双重注意力网络^[6]后添加极化函数以充分提取目标特征,并且该方法在训练时引入动态锚框,使得模型能够动态选择高质量锚框,从而提升模型性能。文献[7]在 Oriented RCNN 网络的基础上改进旋转锚框生成方式,使之更贴合遥感图像中方向呈任意分布的舰船目标,提升模型的检测性能。文献[8]在 SSD 算法的基础上设计浅层特征增强模块,利用特征复用和膨胀卷积增大感受野的尺度和种类,加强网络对纹理信息的提取,并且在设计特征融合网络时利用残差网络和反卷积对不同深层特征进行融合,增强网络的非线性能力和表征能力。文献[9]对有锚框目标检测算法 RetinaNet 进行改进,使用带有角度信息的矩形框对目标进行框选,并且在特征提取时引入 CBAM 注意力模块,增强模型对舰船目标的识别能力。文献[10]通过在特征金字塔之间引入注意力机制以增强全局特征,结合预先设置的先验锚框信息,在舰船目标检测上取得了较好的检测效果。文献[11]提出一种基于自适应和多尺度增强的舰船目标检测算法,通过引入锚框自适应机制生成高质量锚框,并且在特征提取时引入可变形卷积,提取舰船的形状特征,提高检测精度。文献[12]提出一种轻量级遥感图像舰船检测算法,在特征融合时引入坐标注意力机制,突出目标特征,并且在训练阶段设计一种将跨域迁移学习与域内迁移学习相结合的训练策略^[13],减少源域与目标域的差异性,提升迁移学习效果。

上述方法均属于 Anchor-based 的检测方法,在遥感图像舰船目标检测上取得了较好效果,但仍存在一定局限:(1)在设定锚框时需要目标的尺度和类别等先验信息,即预设不同尺度、数量和长宽比的锚框,这在一定程度上影响了网络模型的普适性;(2)设定锚框时会引入较多的超参数,在训练时增加了网络的调节难度,并且在分配正负样本时需对每个锚框进行与 IoU 有关的计算,计算资源消耗较多;(3)预设的锚框数量众多,通过正负样本分配策略使得大多数锚框为包含背景信息的负样本,只有少量锚框为包含信息的正样本,导致正负样本不平衡问题^[14]; (4)没有考虑舰船目标不同长宽比的

影响,如图 1 所示,在预测框与真实框之间的角度偏差相同的情况下,长宽比越大,两框之间的 IoU 越小。由于遥感图像中舰船目标大多呈细长形,长宽比大,使得回归偏差随着目标长宽比的增大而增加,从而影响检测性能。




图 1 不同长宽比对 IoU 的影响

Fig. 1 Effects of different aspect ratio on IoU

针对以上问题,本文提出一种改进 FCOS^[15] 的遥感图像舰船目标检测方法,通过预测每个像素点离旋转目标框的最小外接矩形框的上、下、左、右距离及该矩形框上边中点和右边中点的偏移量,进行任意方向的舰船检测。本文方法无须预定义锚框,避免出现上述与锚框相关的(1)、(2)、(3)问题,提升了检测速度。此外,所提方法在计算中点偏移损失时引入与目标长宽比有关的加权因子^[16],对偏移损失进行约束。根据舰船目标不同的长宽比分配不同的权重,对较大长宽比的目标施加更大的惩罚,提升模型的精确性。

2 相关工作

2.1 FCOS 目标检测模型

FCOS 是一种基于全卷积网络的目标检测算法,主要由主干网络、颈部网络和检测头组成,其网络结构如图 2 所示。图像在经过数据预处理后,送入主干网络进行特征提取;随后将主干网络输出的不同尺度特征输入到颈部网络,进行特征融合;最后将融合特征送入检测头进行目标类别和边框位置预测。该算法属于一阶段无锚框检测算法,无须预定义锚框,显著减少了与锚框有关的超参数数量。在训练时,避免了与 IoU 有关的样本分配复杂运算,训练内存占用空间小。




图 2 FCOS 网络结构图

Fig. 2 Structure diagram of FCOS

FCOS 的主干网络采用 ResNet^[17] 网络模型,由带有残差连接的卷积模块堆叠而成,提取多尺度特征。卷积模块由 1×1 或 3×3 卷积、批归一化和 ReLU 激活函数组成,残差连接以输入直接传递到输出的方式,使得 ResNet 网络可以训练非常深的网络,并且有效避免了梯度消失或梯度爆炸的问题。

FCOS 采用特征金字塔结构^[18] 作为特征融合网络,将 ResNet 网络的第三、四、五阶段的输出特征作为输入,经过 1×1 卷积降维后,对深层特征图进行最近邻插值上采样,随后与浅层特征图相加,以融合不同尺度特征。另外,在原有特征金字塔的基础上对第五阶段的特征进行连续两次下采样操作,最终得到 5 个尺度的特征。

FCOS 的检测头由类别分支(Classification)、中心分数分支(Centerness)和回归分支(Regression)组成。其中,类别分支用于预测每个位置属于各目标类别的概率;中心分数分支表示每个位置与目标框中心点的归一化距离,可以降低距离目标中心较远候选框的置信度;回归分支用于预测每个位置相对于当前位置边界框的 4 个坐标偏移量。FCOS 是通用的目标检测方法,用水平框对目标进行预测。然而,遥感图像中的舰船目标方向任意,若用水平框对舰船目标进行检测,存在框选不精确、部分目标框重叠等问题。因此,本文对检测头进行改进,在原有 FCOS 检测头的基础上,增加一条偏移回归分支,通过偏移水平框的上边中点和右边中点,对舰船目标进行更精确的检测。

2.2 损失函数

FCOS 目标检测网络采用 IoU 系列损失函数^[19] 作为边界框回归损失。不同于距离损失,IoU 损失能够直观反映预测框与真实框之间的重叠程度。然而当两种框不相交时,该

损失函数不可导,无法进一步优化。GIoU^[20] 损失针对此问题引入与预测框和真实框相关的最小外接矩形框,改善了 IoU 损失的计算过程。然而,当两种框处于同一水平位置时,GIoU 损失退化成 IoU 损失,影响模型性能。DIoU^[21] 损失引入两种框中心点之间的距离,直接最小化两种框之间的距离,加快模型收敛。CIoU^[21] 损失通过添加长宽比相似性的惩罚项,进一步优化损失函数。遥感图像中舰船目标通常具有较大的长宽比,在预测框与真实框之间的角度偏差相同的情况下,回归偏差随着目标长宽比的增大而增大,进而影响模型性能。受到 CIoU 损失函数的启发,本文对损失函数进行改进,选用 smoothL1 损失函数作为偏移分支的回归损失,并在此基础上,引入与目标长宽比有关的加权因子,当目标的长宽比越大时,加权因子的数值也越大,加强模型对较大长宽比目标的学习能力,提高边界框预测的准确性。

3 FCOS 目标检测模型的改进

3.1 检测头的改进

FCOS 的回归分支预测特征图上每个位置相对于该位置边界框的左、上、右、下 4 边距离(l, t, r, b),并对其解码,得到水平矩形框。若以此对遥感图像舰船目标进行检测,会出现框选不精确、部分目标框重叠等问题,在后处理阶段,部分检测框易被过滤,导致目标漏检^[22]。为了解决上述问题,对 FCOS 的检测头进行改进,增加一条中点偏移回归支路,结合原有水平框回归支路,产生旋转框,网络结构如图 3 所示。改进后的检测头由两部分组成,第一部分预测目标类别和中心分数,第二部分预测每个位置与旋转目标框的最小外接矩形框的左、上、右、下 4 边距离、最小外接矩形框上边中点和右边中点的偏移量。

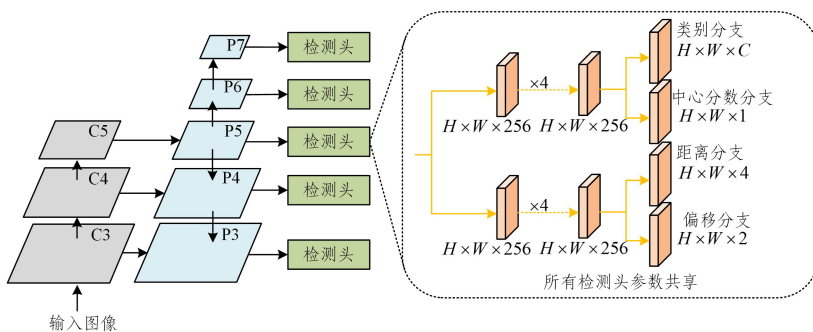


图 3 改进 FCOS 网络结构图

Fig. 3 Structure diagram of improved FCOS

在预测目标类别和中心分数时,通过卷积将类别分支和中心分数分支的特征图通道数分别映射成 $C, 1$,其中 C 表示类别数。每个位置的中心分数表示该点与目标框中心的相对距离分数,越接近目标框中心,中心分数越接近于 1。在训练阶段,中心分数表示如下:

$$ctr^* = \sqrt{\frac{\min(l^*, r^*)}{\max(l^*, r^*)} \times \frac{\min(t^*, b^*)}{\max(t^*, b^*)}} \quad (1)$$

其中, ctr^* 表示该位置的中心分数, l^*, r^*, t^*, b^* 分别表示该位置与真实框的最小外接矩形框的左、右、上、下距离。在推理阶段,将中心分数与相应的类别分数相乘,得到边界框最终的类别分数。中心分数可以降低距离目标中心较远预测框的类别分数,从而在后处理阶段过滤低质量预测框。

在回归得到检测框时,通过一定数量的卷积将距离分支和偏移分支的特征图通道数映射成 $4, 2$,前者表示每个位置

距离旋转框的最小外接矩形框 4 边的距离(l, t, r, b),后者表示最小外接矩形框上边中点和右边中点滑动的距离($\Delta\alpha, \Delta\beta$),即旋转框用($l, r, t, b, \Delta\alpha, \Delta\beta$)6 个参数表示,如图 4 所示。




图 4 旋转框表示

Fig. 4 Rotating bounding box representation

在训练时,对于给定的目标旋转框($x_1, y_1, x_2, y_2, x_3, y_3,$

x_4, y_4), 首先计算最小外接矩形框 $(x_1', y_1', x_2', y_1', x_2', y_2', x_1', y_2')$, 然后按照如下方式进行编码:

$$\begin{cases} l^* = x_p - x_1', & r^* = x_2' - x_p \\ t^* = y_p - y_1', & b^* = y_2' - y_p \\ \Delta\alpha = \frac{x_1 - \frac{x_1' + x_2'}{2}}{x_2' - x_1'} \\ \Delta\beta = \frac{y_2 - \frac{y_1' + y_2'}{2}}{y_2' - y_1'} \end{cases} \quad (2)$$

其中, (x_p, y_p) 表示正样本的像素坐标点, (l^*, t^*, r^*, b^*) 表示该位置距离真实框的最小外接矩形框 4 边的距离, $(\Delta\alpha, \Delta\beta)$ 表示最小外接矩形框上边中点和右边中点滑动的距离。

在推理时, 首先利用位置 (x_p, y_p) 与该点预测的 4 边距离 (l, r, t, b) 按照如下方式得到最小外接矩形框 $H = (x_1', y_1', x_2', y_1', x_2', y_2', x_1', y_2')$:

$$\begin{cases} x_1' = x_p - l, y_1' = y_p - t \\ x_2' = x_p + r, y_2' = y_p + b \end{cases} \quad (3)$$

随后利用该位置预测的偏移量 $(\Delta\alpha, \Delta\beta)$ 和最小外接矩形框按照如下方式进行解码:

$$\begin{cases} x_1 = \frac{x_1' + x_2'}{2} + \Delta\alpha \times (x_2' - x_1'), y_1 = y_1' \\ x_2 = x_2', y_2 = \frac{y_1' + y_2'}{2} - \Delta\beta \times (y_2' - y_1') \\ x_3 = \frac{x_1' + x_2'}{2} - \Delta\alpha \times (x_2' - x_1'), y_3 = y_2' \\ x_4 = x_1', y_4 = \frac{y_1' + y_2'}{2} + \Delta\beta \times (y_2' - y_1') \end{cases} \quad (4)$$

其中, $(x_1, y_1, x_2, y_2, x_3, y_3, x_4, y_4)$ 表示旋转框 4 点的横纵坐标。利用这种方式, 在推理阶段得到旋转框的 4 点坐标。

3.2 损失函数的改进

损失函数主要由两个部分组成, 第一部分包含类别损失和中心分数损失, 第二部分包含位置点与最小外接矩形框 4 边的距离损失和偏移量损失, 改进的损失函数主要体现在第二部分。第一部分损失函数为:

$$L_1 = \frac{1}{N_{\text{pos}}} \sum L_{\text{cls}}(p_{x,y}, c_{x,y}^*) + L_{\text{ctr}}(\text{ctr}_{x,y}, \text{ctr}_{x,y}^*) \quad (5)$$

其中, N_{pos} 表示正样本的数量, $p_{x,y}$ 表示位置点预测的类别概率, $c_{x,y}^*$ 表示该位置点的类别标签, L_{cls} 为焦点损失函数^[23], $\text{ctr}_{x,y}$ 表示位置点预测的中心分数, $\text{ctr}_{x,y}^*$ 为由式(1)得出的中心分数, L_{ctr} 为交叉熵损失函数。

考虑到在角度偏差相同的情况下, 两框之间的交并比随着目标长宽比的增大而减小, 在精度指标评价时直接影响到模型的准确性。为了使模型对该类目标实现更精确的检测, 在训练时引入损失函数因子对中点偏移损失进行约束。第二部分损失函数为:

$$L_2 = \frac{1}{N_{\text{pos}}} \sum_{l,r,t,b} \{l,r,t,b > 0\} L_{\text{Clou}}(d_{l,r,t,b}, d_{l,r,t,b}^*) + \frac{1}{N_{\text{pos}}} \sum_{i=1}^{N_{\text{pos}}} k \times L_{\text{smoothL1}}(d_{\Delta\alpha, \Delta\beta}, d_{\Delta\alpha, \Delta\beta}^*) \quad (6)$$

其中, L_{Clou} 为 Clou 损失函数, $d_{l,r,t,b}$ 为模型预测的位置点与预测框的最小外接矩形框的左、右、上、下的距离, $d_{l,r,t,b}^*$ 为该位置点与真实框的最小外接矩形的左、右、上、下的距离, i 为

正样本的索引值, $d_{\Delta\alpha, \Delta\beta}$ 为模型预测的上边中点和右边中点的偏移量, $d_{\Delta\alpha, \Delta\beta}^*$ 为真实框的最小外接矩形框上边中点和右边中点的偏移量, L_{smoothL1} 表示 smooth L1 损失^[24]。 k 为损失函数因子, 表示如下:

$$k = 1 + e^{-1/\text{rat}_i} \quad (7)$$

其中, rat_i 表示真实框的长宽比, 当目标的长宽比越大, 损失函数因子 k 越大, 在偏移损失中的权重也相应变大, 使得模型对具有较大长宽比的目标施加更大的惩罚, 从而有助于该类目标物体更准确地回归, 提高模型的检测精度。

4 实验结果与分析

4.1 数据集及评价指标

本文在西北工业大学公开的高分辨率遥感图像舰船检测数据集 HRSC2016^[25] 上进行实验, 其图像来自于 Google Earth 上 6 个著名港口, 图 5 给出了 4 幅示例图像。HRSC2016 数据集一共包含 1061 幅图像, 2976 个舰船目标。其中训练集、验证集和测试集的图像数分别为 436, 181 和 444, 每幅图像分辨率处于 2 m~0.4 m 之间, 每幅图像大小处于 300×300 到 1500×900 之间。实验中, 在不改变目标长宽比的情况下将每幅图像调整为 800×800 固定大小, 选取训练集和验证集共 617 幅图像进行训练, 在测试集上进行精度和速度测试。



图 5 HRSC2016 数据集样例

Fig. 5 Samples of HRSC2016 dataset

由于数据集中只有舰船一类目标, 故采用在 $IoU = 0.5$ 的平均精确度 (Average Precision, AP) 作为精度评价指标, 在表 1 中记为 AP50, 利用准确率 (Precision) 和召回率 (Recall) 得到 P-R 曲线, AP50 即为 P-R 曲线的面积。Precision (P)、Recall (R) 和 AP50 的计算式如下:

$$P = \frac{T_{\text{TP}}}{T_{\text{TP}} + F_{\text{FP}}} \times 100\% \quad (8)$$

$$R = \frac{T_{\text{TP}}}{T_{\text{TP}} + F_{\text{FN}}} \times 100\% \quad (9)$$

$$AP50 = \int_0^1 P(R) dR \quad (10)$$

其中, T_{TP} 表示正确检测出的舰船目标数量, F_{FP} 表示被错误检测成舰船目标的数量, F_{FN} 表示舰船目标被漏检的数量。计算每个模型的空间复杂度, 其主要为模型中可训练的权重和偏置参数的数量, 在表 1 中表示为参数量; 计算每秒内检测出 800×800 大小的图像数量, 即每秒帧数 FPS (Frames Per Second) 作为速度评价指标。

表 1 本文算法与其他算法的精度和速度对比

Table 1 Precision and speed comparison between the proposed algorithm and other algorithms

方法	主干网络	锚框类型	AP50/%	参数量	FPS
CNRC	ResNet101	无锚框	83.60	55.60×10^6	19.3
Oriented Reppoints	ResNet101	无锚框	88.00	55.60×10^6	19.4
CFA	ResNet101	无锚框	86.80	55.62×10^6	19.3
FCOS-OBB	ResNet101	无锚框	87.20	50.88×10^6	21.6
改进 FCOS	ResNet101	无锚框	89.00	50.88×10^6	19.8

4.2 实验设置

本文基于 Pytorch 深度学习框架,所有实验均在 64 位 Linux 操作系统 Ubuntu 18.04 上进行,CPU 型号为 Intel Core i7-7800X,GPU 型号为 NVIDIA GTX 1080Ti,11GB 显存。在实验中,GPU 可通过硬件加速实现更快的矩阵乘法、卷积操作等运算,加速模型的训练和推理,提高计算效率。为了避免过拟合,所有方法在训练时均使用随机翻转以实现数据增强,批量大小设置为 2,采用随机梯度下降法(SGD)对模型进行优化,初始学习率设置为 0.0025,动量为 0.9,权重衰减为 0.0001,在非极大值抑制时将阈值设置为 0.1,以去除重复检测框。将本文方法与 Oriented Reppoints^[26],FCOS-OBB^[27],CNRC^[28],CFA^[29]等当前具有代表性的几种无锚框算法进行比较,对于本文方法、Oriented Reppoints、FCOS-OBB,我们训练 36 轮并且在第 24 轮和 33 轮时将学习率降低至原来的 1/10。对于 CNRC,CFA,为了使模型收敛,训练 72 轮并在第 48 轮和 66 轮时将学习率降低至原来的 1/10。

4.3 对比实验

为了验证本文方法的有效性,将本文方法与文献^[26-29]等目标检测算法在 HRSC2016 数据集上进行对比实验。为了公平起见,将所有方法的主干网络均设置为 ResNet101,各检测算法在 HRSC2016 测试集上的检测结果如表 1 所列。所有对比方法的模型代码均来自于 OpenMMLab^[30]平台。

由表 1 可知,CNRC,Oriented Reppoints 和 CFA 均为无锚框检测方法,检测精度分别为 83.60%,88.00%和 86.80%,检测速度分别达到了 19.3FPS,19.4FPS 和 19.3FPS。这些算法均为遥感图像旋转目标检测的无锚框算法,检测速度较快。FCOS-OBB 为在 FCOS 的回归分支上添加角度信息而成,该方法对角度进行损失计算时采用距离损失,没有考虑角度周期性问题^[31],影响了模型性能,因此只取得 87.20%的检测精度。本文方法与 FCOS-OBB 不同,通过在水平框的基础上偏移上边中点和右边中点,得到旋转框,避免了上述角度周期性问题,故检测精度达到 89.00%,较 FCOS-OBB 提升 1.80%,在上述无锚框检测方法中取得了最高精度,在检测速度上略高于 CNRC,Oriented Reppoints 和 CFA 等算法。总体而言,本文方法在检测精度与速度上达到了均衡。

4.4 消融实验

为了评估改进的偏移回归分支和改进的损失函数的有效性,我们设计一组消融实验,在 FCOS 网络模型的基础上,依次加入偏移回归分支、损失函数加权因子,进行结果对比分析。另外,由于当前旋转目标检测方法的常用构成方式为在通用水平框目标检测方法的基础上加入角度分支,使得模型能够检测方向任意的目标物体,因此,为了进一步验证偏移回

归分支的有效性,我们在 FCOS 水平框目标检测网络的基础上加入角度分支,并与加入偏移回归分支的结果进行对比分析。检测结果如表 2 所列。

表 2 消融实验数据

Table 2 Ablation experiment data

FCOS	偏移回归分支	角度分支	损失函数加权因子	AP50/%
✓				53.10
✓		✓		87.20
✓	✓			88.50
✓	✓		✓	89.00

由表 2 可知,FCOS 算法在 HRSC2016 数据集上的检测精度只有 53.10%,因其检测框中包含大量背景,检测效果较差。加入角度分支后,检测精度提高至 87.20%,表明旋转框更适用于方向任意的遥感图像舰船检测;在 FCOS 的基础上增加偏移回归分支,检测精度为 88.50%,较引入角度分支的方法提高了 1.30%,这得益于利用偏移分支产生的旋转检测框避免了角度周期性,提高了模型精度;在偏移分支的基础上加入损失函数因子,模型的整体性能再次升高 0.5%,表明针对舰船目标引进损失函数长宽比因子是有效的。

图 6 给出了原始 FCOS、CNRC、Oriented Reppoints、CFA、FCOS-OBB 和本文方法在 HRSC2016 测试集的检测效果。

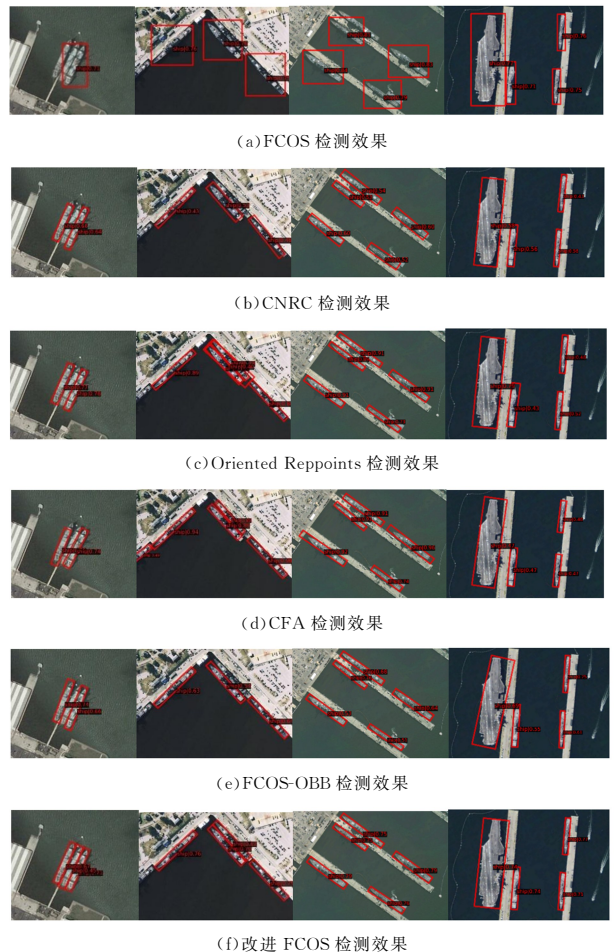


图 6 各检测算法效果对比

Fig. 6 Effect comparison of each detection algorithm

从图 6(a)可以看出,对于图像中呈稀疏分布的舰船目标,基线算法基本能检测出其位置。不过受制于 FCOS 算法水平框的局限性,检测框中附带大量背景,检测效果较差。对于图像中密集排列分布的舰船目标,基线算法存在较为严重的漏检情况。造成这一现象的原因是多个目标检测框重叠率过高,在后处理阶段使用非极大值抑制过滤了部分检测框。CNRC 算法、Oriented Reppoints 算法、CFA 算法和 FCOS-OBB 算法的部分检测结果分别如图 6(b)~图 6(e)所示。从图中可以看出,对于密集分布的目标,上述算法均存在一定程度的漏检,CNRC 算法和 FCOS-OBB 算法的检测框置信度整体偏低,Oriented Reppoints 算法的检测框置信度较高,但易出现误检,CFA 算法在舰船目标的框选上不够精确。改进后的 FCOS 算法检测结果如图 6(f)所示,检测效果优于上述算法,对任意分布的舰船目标具有较强的检测能力,可以准确地检测出舰船目标。

结束语 本文提出一种改进 FCOS 的遥感图像舰船目标检测算法,通过改进 FCOS 检测头的回归分支和损失函数,使得模型对目标的框选更为准确,从而提升模型性能。实验结果表明,该算法在遥感图像舰船数据集 HSRC2016 上取得了 89% 的检测精度,在相同的实验环境下性能优于同类型的无锚框检测算法。下一步将对该算法网络结构进行轻量化处理和部署工作,加快模型的检测速度,进一步提高其实际应用价值。

参 考 文 献

- [1] ZHU Y, FANG G S, ZHENG B B, et al. Research on detection method of refined rotated boxes in remote sensing[J]. *Acta Automatica Sinica*, 2023, 49(2): 415-424.
- [2] DING J, XUE N, XIA G S, et al. Object detection in aerial images: A large-scale benchmark and challenges[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021, 44(11): 7778-7796.
- [3] ZHANG Z, YI H H, ZHENG J. Focusing on small objects detector in aerial images[J]. *Acta Electronica Sinica*, 2023, 51: 994.
- [4] YANG X, SUN H, FU K, et al. Automatic ship detection in remote sensing images from google earth of complex scenes based on multiscale rotation dense feature pyramid networks[J]. *Remote Sensing*, 2018, 10(1): 132.
- [5] SONG Z N, LI S, YANG J M, XU C. Remote sensing ship target detection based on feature and region localization enhancement [J/OL]. *Computer Engineering*, 2023, 49(8): 257-264.
- [6] FU J, LIU J, TIAN H, et al. Dual attention network for scene segmentation[C]// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2019: 3146-3154.
- [7] ZHOU G Q, HUANG L, SUN Q. Fine-grained detection method for remote sensing ship targets with improved Oriented R-CNN [J]. *Computer Engineering and Applications*, 2022, 44(6): 1823-1832.
- [8] ZHANG T, YANG X G, LU X Q, et al. Ship detection in remote sensing image based on dense RFB and LSTM[J]. *National Remote Sensing Bulletin*, 2022, 26(9): 1859-1871.
- [9] JIAO J F, JING W, XIONG X. SAR images nearshore ship detection based on RetinaNet algorithm with rotated Rectangular box[J]. *Journal of Geomatics Science and Technology*, 2020, 37(6): 603-609.
- [10] ZHAO Y, ZHAO L, XIONG B, et al. Attention receptive pyramid network for ship detection in SAR images[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2020, 13: 2738-2756.
- [11] SHAO Z K, ZHANG X L, ZHANG T W, et al. A SAR ship detection method based on adaptive anchor and scale enhancement [J]. *Systems Engineering and Electronics*, 2024, 46(4): 1204-1211.
- [12] WANG H Y, WANG C P, FU Q, et al. Ship detection based on lightweight optical remote sensing images for embedded platform[J]. *Acta Optica Sinica*, 2023, 43(12): 121-134.
- [13] BUKHSH Z A, JANSEN N, SAEED A. Damage detection using in-domain and cross-domain transfer learning[J]. *Neural Computing and Applications*, 2021, 33(24): 16921-16936.
- [14] LIU X B, XIAO X, WANG L, et al. Anchor-free based object detection methods and its application progress in complex scenes [J]. *Acta Automatica Sinica*, 2022, 48(x): 1-23.
- [15] TIAN Z, SHEN C, CHEN H, et al. Fcos: Fully convolutional one-stage object detection[C]// *Proceedings of the IEEE/CVF International Conference on Computer Vision*. 2019: 9627-9636.
- [16] LIU S, ZHANG L, LU H, et al. Center-boundary dual attention for oriented object detection in remote sensing images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 60: 1-14.
- [17] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2016: 770-778.
- [18] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2017: 2117-2125.
- [19] YU J, JIANG Y, WANG Z, et al. Unitbox: An advanced object detection network[C]// *Proceedings of the 24th ACM International Conference on Multimedia*. 2016: 516-520.
- [20] REZATOFIGHI H, TSOI N, GWAK J Y, et al. Generalized intersection over union: A metric and a loss for bounding box regression[C]// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2019: 658-666.
- [21] ZHENG Z, WANG P, LIU W, et al. Distance-IoU loss: Faster and better learning for bounding box regression[C]// *Proceedings of the AAAI Conference on Artificial Intelligence*. 2020, 34(7): 12993-13000.
- [22] NEUBECK A, VAN GOOL L. Efficient non-maximum suppression[C]// *18th International Conference on Pattern Recognition (ICPR'06)*. IEEE, 2006, 3: 850-855.
- [23] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[C]// *Proceedings of the IEEE International Conference on Computer Vision*. 2017: 2980-2988.
- [24] GIRSHICK R. Fast r-cnn[C]// *Proceedings of the IEEE International Conference on Computer Vision*. 2015: 1440-1448.
- [25] LIU Z, YUAN L, WENG L, et al. A high resolution optical sa-

tellite image dataset for ship recognition and some new baselines [C]//ICPRAM, 2017:324-331.


- [26] LI W, CHEN Y, HU K, et al. Oriented reppoints for aerial object detection [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022:1829-1838.
- [27] ZHOU Y, YANG X, ZHANG G, et al. Mmrotate: A rotated object detection benchmark using pytorch [C] // Proceedings of the 30th ACM International Conference on Multimedia, 2022:7331-7334.
- [28] GAO L, GAO H, WANG Y, et al. Center-ness and repulsion: Constraints to improve remote sensing object detection via reppoints [J]. Remote Sensing, 2023, 15(6): 1479.
- [29] GUO Z, LIU C, ZHANG X, et al. Beyond bounding-box: Convex-hull feature adaptation for oriented and densely packed object detection [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021:8792-8801.
- [30] CHEN K, WANG J, PANG J, et al. MMDetection; Open mmlab

detection toolbox and benchmark [J]. arXiv:1906.07155, 2019.

- [31] YANG X, YAN J. On the arbitrary-oriented object detection: Classification based approaches revisited [J]. International Journal of Computer Vision, 2022, 130(5): 1340-1365.



CHEN Tianpeng, born in 1996, post-graduate. His main research interests include deep learning and object detection in remote sensing images.



HU Jianwen, born in 1985, Ph.D, post-graduate supervisor. His main research interests include artificial intelligence, computer vision and machine learning.