

针对新学习策略的弱小目标检测方法

薛锦¹, 田增焯², 师庆科¹, 文占婷³

(1. 四川大学 华西医院信息中心, 成都 610041;

2. 成都信息工程大学 应用数学学院, 成都 610225;

3. 中电科网络安全科技股份有限公司, 成都 610041)

摘要: 基于深度卷积神经网络的目标检测在应用中展现出了良好的性能, 然而, 将其应用于弱小目标检测上依然性能欠佳; 为了提高弱小目标检测速度和精度的性能, 文章提出一种有效的弱小目标检测方法, 使用改进的特征提取方法, 利用尺度匹配策略选取合适的尺度进行弱小目标检测; 同时在神经网络中设计自适应的融合模块, 通过融合特征与接收域以增强目标环境特征; 提出的方法在检测速度和精度上都具备良好的性能; 有效解决了一般的框策略无法准确获取弱小目标的问题, 新的策略使用自适应参数确定检测框; 特别针对海天背景下, 检测海面船只问题, 提出基于海天智能分割的方法, 进而进行背景处理检测的预处理方法; 可以很大程度消除虚警, 提高目标检测概率; 实验结果表明, 提出的方法在视频数据中能够有效检测弱小目标, 优于其它先进的目标检测方法。

关键词: 深度卷积神经网络; 弱小目标; 红外图像; 自适应融合模块

Detection Method of Weak and Small Targets for New Learning Strategies

XUE Jin¹, TIAN Zengxian², SHI Qingke¹, WEN Zhanting³

(1. Information Center of West China Hospital, Sichuan University, Chengdu 610041, China;

2. School of Applied Mathematics, Chengdu University of Information Engineering, Chengdu 610225, China;

3. CETC Network Security Technology Co., Ltd., Chengdu 610041, China)

Abstract: Based on deep convolution neural network, target detection has a good performance in application, however, its performance is still poor for weak and small target detection. In order to improve the speed and accuracy of the small and weak target detection, an effective small and weak target detection method is proposed, the improved feature extraction method and scale matching strategy are used to select appropriate scale for the small target detection, at the same time, an adaptive fusion module is designed in the neural network, the characteristics of the target environment are enhanced by fusing the features and receiving the domain, the proposed method has a good performance in detection speed and accuracy, and effectively solves the problem that the general box strategy cannot accurately obtain small targets, the new strategy uses adaptive parameters to determine the detection box. Especially for the detection of ships in the sea and sky background, an intelligent segmentation method of the sea and sky line is proposed, and then the background detection preprocessing method carried out, which largely eliminates false alarms and improves the probability of target detection. Experimental results show that the proposed method can effectively detect weak and small targets from the video data, and it is superior to other advanced target detection methods.

Keywords: deep convolution neural network; weak and small targets; infrared image; adaptive fusion module

0 引言

弱小目标检测在导航、侦察、精确打击、打击效果评估中起着重要的作用^[1-2], 一直是计算机视觉领域的研究热点, 广泛应用于许多领域^[3], 如行人检测、智能监控、自动驾驶以及压缩测量领域的目标检测和分类等^[4]。在图像处理中, 目标检测非常具有挑战性, 需要对目标分类并定

位^[5-6]。出于安全性考虑, 战斗机必须从远距离处攻击地面目标, 目标在图像中占的像素比很低, 目标检测的难度很大^[7]。

鉴于目标和背景杂波的极端复杂性及红外图像的低分辨率, 使得红外视频中小型目标舰船自动检测成为现代军事应用中的一项目瓶颈技术。海天区域即海天附近

收稿日期: 2023-02-08; 修回日期: 2023-03-10。

基金项目: 国家科技部项目(2020YFC2003404)。

作者简介: 薛锦(1991-), 女, 四川资阳人, 硕士, 助理工程师, 主要从事计算机技术与应用、医院信息化系统规划和建设方向的研究。

引用格式: 薛锦, 田增焯, 师庆科, 等. 针对新学习策略的弱小目标检测方法[J]. 计算机测量与控制, 2023, 31(6): 34-39.

区域, 海天线为海与天之间的边界线。在基于图像的目标检测时, 小型舰船经常出现在海天线附近。受海天线干扰, 使目标检测非常困难。本文重点关注海天场景下目标检测问题, 尤其是海天线附近的弱小目标检测。

舰船目标在一般情况下, 在红外图像中呈现的图像特征为强度弱、信噪比低、形状特征不明显, 目标检测和识别非常困难。兼之红外背景复杂、混乱, 对比度不够。杂波背景的复杂性是由于传感器噪声、背景纹理、成像环境。且杂波背景均匀性较差, 产生高对比度物体的可能性增加, 从而会导致虚警增加。随着外部大气和热力学因素的变化, 红外图像中目标及背景杂波外观会发生较大变化。另外, 在视频中的目标成像会在时空域上发生变化, 会导致目标轮廓检测及准确提取困难。在很多场景下, 目标与噪声、杂波非常类似, 无法将真实目标与背景、噪声分开, 检测性能并不理想。

一般将检测小目标的模式分为两种, 跟踪前检测及检测前跟踪。对于前者, 很多学者提出了检测方法。比如形态学方法, 基于小波变换方法, 基于模板匹配的方法等。这些方法的好处为计算检测, 实时性好。在海天红外辐射背景下, 小目标在海天线附近成像形式为明暗光斑, 天气条件对目标的红外辐射特征会产生重要影响, 在晴朗天气, 背景变暗, 运动目标在图像上显示为点源辐射。但在恶劣天气下, 成像受海浪及云层污染, 目标湮灭在杂波中, 跟踪前检测算法精度较低甚至会失效。但在海天线指引下, 可提出一些有效的算法, 抑制杂波, 增强目标。海天线检测直接影响目标检测性能。但在某些情况下, 海天线并不明显, 会受到海浪及云层干扰, 将严重干扰目标稳定检测。一些学者提出了许多新颖、巧妙的方法对海天线进行自动检测, 但未能适配各种条件下的自动海天线检测定位。

在传统方法中, 使用尺度不变特征的变换、局部二值模式等方法。然而, 这些特征很难适应某些特定的任务, 效果很难令人满意^[7-8]。随着 GPU 的发展, 一些学者在目标检测模型中嵌入卷积神经网络的深度学习模型 (简称 CNN) 处理图像, 目标检测精度逐渐提高^[9]。区域 CNN 算法使用区域分块方法在输入图像中产生大量区域块, 并将区域调整为相同大小^[10]。然后, 在这些区域上进行 CNN 处理以提取特征。利用支持向量机对输入的特征进行分类, 线性回归用于调整边界的位置和尺度。由于支持向量机和线性回归必须分别训练, 并且大量区域块之间存在重叠^[10], 因此区域 CNN 算法效率很低。快速区域 CNN 算法通过多线程方法将分类和识别结合, 使用末端卷积层的九个不同框以替代大量候选区域^[11-12], 该算法在处理效率上虽有提高, 但依然未能令人满意, 针对特征多的对象容易形成数据灾难, 同时当数据量不足时极有可能训练不足, 导致预测精度下降。YOLO 算法将该问题简化, 成为端到端的网络, 同时支持预测和分类, 检测速度有了很大提高, 但检

测精度低于快速区域 CNN 算法。

在快速区域 CNN 中的机制下^[13-14], 使用 SSD 算法也可快速提高检测精度。这种算分创造出的一系列默认的区域块^[15-17], 并对多层框中对象实例进行计算。通过对 SSD (single shot multibox detector) 算法的不同预测, 及默认策略覆盖输入对象的尺寸和形状。默认的框制约因素有: 比例及纵横比, 为不同的图层的框提供基本比例及默认框的大小及数量^[18]。由于弱小目标本身在最顶层可能没有任何信息, 于是 SSD 算法对于小目标检测性能会很差^[19]。更深刻的原因是, 原始默认参数仅用于检测合适尺度的目标, 而非针对小目标检测^[20]。若增加默认框的数量, 可能会降低 SSD 算法的收敛性。

这篇文章提出一种基于新学习策略的弱小目标检测方法, 自适应尺度信息, 按照多层定义策略, 可更快、更准确检测小目标。

1 新学习策略方法

基于 DCNN 的目标检测器可以分为两类。一种是两级目标检测器, 如 R-CNN、Fast R-CNN、Faster R-CNN 和 Mask R-CNN 等。R-CNN 首先通过选择性搜索生成大量候选方案。然后, 利用检测网络进一步预测目标的类别和位置。Fast R-CNN 引入了兴趣区域池 (ROI 池) 来融合来自特征地图每个区域的特征。为了提高检测器的效率, 更快的 R-CNN 通过引入区域建议网络 (RPN) 来减少低级建议。Mask R-CNN 将任务从检测扩展到分割。另一种是单级目标检测器, 如 SSD、YLO、YLO 9000、YLO V3、CenterNet 和 CornerNet 等。它们是端到端目标检测算法, 因为它们可以直接预测目标的位置和类别。SSD 使用特征金字塔结构来检测不同大小的目标, 并提出一种生成锚盒的策略。YOLO、YOLO 9000 和 YOLO V3 将图像划分为多个网格, 并预测每个网格中的目标。YOLO V3 采用特征金字塔网络的思想, 对目标进行多尺度检测。CenterNet 和 CornerNet 提出了无锚策略来检测目标的关键点。

传统的 SSD 方法不适合针对小目标的检测, 制定新策略用于特定场景的检测, 包括自适应的尺度及纵横比。新尺度中, 核与卷积层的尺度比用于替代固定的增量。在新纵横比中, 每层纵横比数量将减少。与较低层的纵横比数对比, 增加了高层的纵横比数量。于是, 可从顶层获取更多有用信息。

原始的范围用于覆盖目标的所有尺度。在较低层次, 算法中使用小比例增量以确保较小的纵横比, 也可很好捕获小目标的细节信息。在更高的层次上, 使用大尺度增量来捕获轮廓信息。对于小型目标, 其比例一定不会像顶层中正常目标尺度一样。于是, 顶层的设置比例要小于原始比例。新比例增量的值在较低层较小, 在较高层较大。

尺度公式如下:

$$\sigma_c = \sigma_{\min} + (\sigma_{\max} - \sigma_{\min}) / \tau_{c-1} \cdot \kappa_{c-1} \quad (1)$$

其中: τ_{c-1} 表示 $c-1$ 层的长度, κ_{c-1} 表示 $c-1$ 卷积层内核

的长度。

设计的网络能够通过多尺度训练,在多样化尺度的图像上运行,有效提高检测性能。在弱小目标检测中,输入图像中大部分区域都是背景,为在大范围内检测目标,需对图像进行感兴趣区域划分,对冗余的区域进行识别。首先,根据真实场景搜索包含小目标的最小区域。去除图像中多余的背景后,大部分背景不参与训练,虚警率会增加。为缓解问题,将感兴趣区域与原始图像一同作为训练数据集。在训练阶段,所有的图像均调整为相同大小。与原始训练集相比,给出的训练集中的小目标可在更大范围内训练而不会增加记忆。

另外,根据不同分层在图像上应该具有相同密度的原则,以确保不同比例的目标可获得大致匹配的指标。不同层应该以 2 的幂进行降阶匹配。因此,在每个尺度上密度的变化都非常小,为选择合适的密度范围,对视频数据集进行了大量的分析。结论为低分辨率的特征包含了颗粒度信息,有助于目标定位。高分辨率特征包含了更多有意义的理解信息,有助于对目标进行分类。若密度低,小目标会淹没在大目标中,若密度高,大目标将会被分割成很多小份,分割非常不合理。小目标周边上下文信息对小目标检测非常有用。延拓卷积可在不丢失分辨率或覆盖率的条件下扩展接受域,将有助于获取更多的上下文信息。于是,以扩展卷积为基本单元,构建自适应融合模块。

2 海天线检测

由于红外海天背景图像中小目标经常出现在海天线附近,因此识别海天线是目标检测的重要线索。海天线的检测是海天背景下小目标检测的首要步骤,可以很大程度消除虚警,提高目标检测概率。

为有效区分海天不同区域的差异,设计一种新的特征描述子,对该描述子的需求为:在海天区域中心处达到峰值,在其他区域响应值较小。采用横向搜索方式,检测海天线段:

$$SSSD(h) = \int_h^{h+\sigma/2} \int_0^W \left[I(x,y)^2 - I\left(x,y + \frac{\sigma}{2}\right)^2 \right] dx dy \quad (2)$$

其中:SSSD 为检测描述子, h 为待检测图像的列宽, σ 为检测宽度, W 为待检测图像的行宽,通过积分手段将不同区域的差异进行积分, I 为图像函数, x , y 分别为图像像素坐标。由于 SSSD 代表图像的复杂性,其反映了图像中海天候选区域的数量。在低杂波场景下,海区和天空区有轻微的海杂波和明亮的云,海天线非常清晰。因此,很容易分离天空区域和海洋区域。在此情况下,应用高斯低通滤波器去除异常高斯白噪声并增强获得的红外图像质量。分割后,红外图像的天空区域和海洋区域分别被分割成具有垂直空间分布特征的块区域,并通过提取的特征对其进行验证。然后将概率最大的区域作为海天区域。最后,提取特征并验证潜在的海天线是否准确。

在低杂波场景下,海区和天空区有轻微的海杂波和明

亮的云,海天线非常清晰。因此,在天空区域和海洋区域相互分离后,可以很容易地从背景中提取海洋天空线。在这种情况下,使用高斯低通滤波器去除异常高斯白噪声并增强获得的红外图像的图像质量,然后,使用经典的 Otsu 方法进行区域分割。分割后,红外图像的天空区域和海洋区域分别被分割成具有垂直空间分布特征的水平块。因此,重要的一步是从这些块中提取潜在的海天区域,并通过提取的特征对其进行验证。然后将概率最大的区域作为海天区域。可以提取并验证潜在的海天线是否真实。首先,特征提取和获取区域属性。经过图像预处理和分割后,各块在分割后的结果图像中呈现垂直空间分布,每个潜在海天区域假设位于高度为 h 的邻域块的中间。然后,从所有潜在海天区域提取特征。同时,获取由宽度、高度、质心和面积组成的区域属性。然后,海天区域验证。在获得特征和属性后,利用特征对每个潜在海天区域进行验证,然后将概率最大的区域作为海天区域。之后,完成潜在海天线提取和验证。接着,进行海天线定位。验证海天区域的质心和飞机的横滚分别被视为海天线的顶点和角度。最后,在红外图像中检测并定位了海天线。

在高杂波场景中,海天背景也受到云杂波和波杂波的强烈污染。在这种情况下,海天区域的直线成为重要信息,有助于找到潜在的海天线。在图像预处理后,采用基于 Canny 算子的经典直线提取方法,提取增强图像的模糊和清晰边缘,长度大于阈值的直线均被视为潜在海天线。然后,使用提取的特征在附近区域验证这些潜在的海天线。最后,将概率最大的潜在海天线视为真实海天线。

3 基于二值决策的目标分割算法及检测

目标增强和背景抑制算法直接影响检测性能。在小目标增强领域已提出很多方法,如 Top-Hat 方法、Max-Median、Max-Mean。以目标比背景亮的假设作为基础的多级滤波器,效果明显。上述方法认为在低频中背景占主导地位,目标由中频构成,高频中以噪声为主。利用频率差抑制杂波背景,增强目标。此篇文章提出一种基于二值决策的目标分割算法。定义决策准则:

$$\begin{cases} P_0: I = B + N \\ P_1: I = T + B + N \end{cases} \quad (3)$$

其中: T 为红外目标空间函数分布, B 为背景空间函数分布, N 为噪声空间分布函数, P_0 为无目标图像函数分布, P_1 为有目标时图像函数分布。

由上述决策公式可获得原始图像的预处理方法:在采集的图像上减去预测的背景图像完成背景抑制,处理完成后,重写决策准则公式为:

$$\begin{cases} Q_0: I = N + C \\ Q_1: I = T + N + C \end{cases} \quad (4)$$

其中: C 为背景抑制残差,该函数与设计的滤波器紧密相关,按照高斯低通滤波器设计,表示为 $C = \text{Filter}(\Omega)$,

Ω 为截止频率, 值与滤波效果呈负相关。

定义阈值为 λ , 通过该值进行图像分割, 在概率空间表示为:

$$\begin{cases} G_0(\Omega, \lambda) = G(\text{Filter}(\Omega) + N > \lambda) \\ G_1(\Omega, \lambda) = G(\text{Filter}(\Omega) + N + T > \lambda) \end{cases} \quad (5)$$

当存在目标时, 设定终极函数 $G(\text{Filter}(\Omega) + N + T > \lambda)$, 当函数值达到最大时, 滤波效果最好, 可获得最佳滤波值 λ_{\max} 、 Ω_{\max} 。

在实测中, 用于估计参数值时, 需目标的预估信噪比, 背景的分布函数以及预期的检测概率, 通过优化算法, 获得最佳参数。

在抑制背景后, 目标局部对比度得到明显增强。之后进行全局 Otsu 二值分割, 得到疑似目标的宽度、高度、质心和面积等属性。然后在疑似目标区域范围内再运行局部 Otsu 二值分割算法, 并对目标进行分类。直至无新的目标产生, 算法结束。通过运算, 虚警成为干扰目标提取的重要因素。利用海天线检测的结果对虚警进行抑制。

4 算法流程

提出算法的流程如图 1~2 所示。

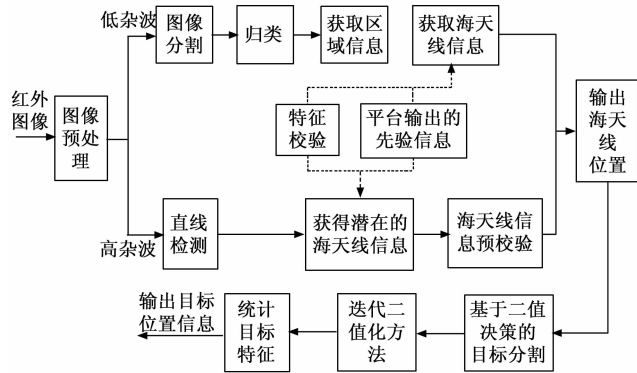


图 1 算法预处理流程图

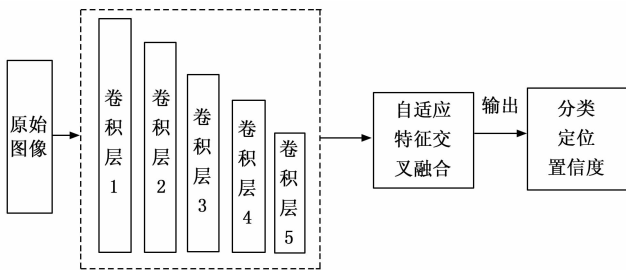


图 2 算法流程图

1) 预处理流程: 首先对输入的红外序列图像进行预处理, 判别杂波性能, 分两种情况对图像进行处理。在低杂波条件下, 对图像进行分割, 归类并获取区域信息, 得到海天线; 在高杂波条件下, 对图像直线进行检测, 获取疑似海天线信息, 并进行校验。在不同的情况下, 利用特征及平台输出的先验信息对海天线进行校验。然后, 输出海

天线位置, 对其进行多级滤波器滤波, 进行迭代二值分割, 并统计目标特征, 最后输出目标的位置信息。

2) 算法流程: 对输入的图像根据目标尺度生成覆盖目标的全部尺度卷积层, 保证设计的网络可覆盖多样化尺度图像, 可有效提高目标检测性能。使用自适应特征交叉融合模型, 输出目标的分类、定位、置信度量。

5 实验结果及分析

为有效评估算法的性能, 在采集的数据集及存在小目标的数据集上进行对比实验。用于对航拍图像进行小目标检测。目标在图像上占有的面积在 $5 \times 5 \sim 10 \times 10$ (像素) 之间。

训练在高端显卡配置下的服务器上进行训练, 实验编程语言为 Python。在训练和测试阶段, 输入图像的大小均调整为 1024×1024 。

通过融合, 背景训练使用率有了明显提高, 增强了目标识别的能力。在保持高检测速度的同时, 检测指标的提高也很显著。通过权重共享, 使得模型健壮性更强。通过感兴趣区域的提取, 在不影响检测速度的同时, 背景利用率提高了 8.2%。可保证在更大范围内对目标进行训练, 有助于提高小目标的检测性能。

为定性评估算法性能, 在 4 组图像中进行试验, 测试结果如图 3 所示, 由图中处理的结果可见, 经过海天线检测, 分段处理不同区域的图像, 再经过基于新学习策略的算法处理后, 舰船目标被清晰分割了出来。试验结果表明, 提出的算法对海天背景下小目标的检测十分有效。




图 3 提出算法检测结果

为进一步验证提出算法的性能, 进行对比实验, 采用的对比算法有 CNN、RCNN、Faster RCNN、YOLO 以及提出的算法, 选取 mAP 指标 (mean average precision, 即所有类别 AP 的平均值), 指标 mAP 的测试对比表如表 1。由 mAP 指标的性质可知, 作为一个相对较好的度量指标 mAP 可有效衡量比较出不同目标检测算法的优劣。由表中可知, 提出算法的 mAP 值较高, 代表其可在这类场景中效果超过其它算法。本文提出的算法 mAP 值计算结果针对图 1~6 分别为 39.412、19.572、29.190、28.491、22.651、9.117 3, 其它算法中效果最好的 YOLO 算法为: 39.298、18.003、28.315、29.340、21.387、8.474 1, 可见, YOLO 效果虽然较好, 但依然不如本文提出的算法。

表 1 小目标数据集的检测结果

检测算法	图 1	图 2	图 3	图 4	图 5	图 6
CNN	23.152	11.419	10.714	26.787	9.280	5.230 9
RCNN	30.938	14.218	23.115	27.577	5.796	5.485 7
Faster RCNN	39.150	14.854	25.844	27.431	14.806	6.384 6
YOLO	39.298	18.003	28.315	29.340	21.387	8.474 1
Proposed	39.412	19.572	29.190	28.491	22.651	9.117 3

表 2 为算法检测时间对比表, 根据测量单帧处理时间信息, 按照 CNN、RCNN、Faster RCNN、YOLO 以及提出的算法的顺序, 处理的平均时间分别为 0.416 1、0.788 0、0.634 6、1.281 9、0.579 8, 可见, 提出的算法计算效率为中等, 但综合检测效能和计算消耗, 性价比最高。结论: 本文提出的算法计算耗时与 Faster RCNN 相当, 可满足绝大多数应用需求。

表 2 小目标数据集的检测时间表

检测算法	CNN	RCNN	Faster RCNN	YOLO	Proposed
单帧处理 时间/s	0.396 5	0.778 0	0.636 7	1.290 3	0.598 9
	0.440 3	0.778 8	0.617 9	1.287 3	0.578 5
	0.417 3	0.794 9	0.637 2	1.277 0	0.579 3
	0.409 4	0.794 1	0.646 3	1.282 9	0.581 9
	0.417 1	0.794 2	0.634 9	1.272 1	0.560 6
平均/s	0.416 1	0.788 0	0.634 6	1.281 9	0.579 8

定义局部信杂比增益 SCRG 用于提出算法的性能测试:

$$SCRG = \frac{SCR_{out}}{SCR_{in}}$$

SCR_{out} 为算法输出图像的目标信杂比, SCR_{in} 为算法输入图像的目标信杂比。

测试完毕后, 如表 3 所示, CNN、RCNN、Faster RCNN、YOLO 以及提出的算法的平均 SCGR 值分别为 8.03、8.96、12.07、14.24、30.60。可见, 提出算法在处理完毕图像后, 目标的局部信杂比增益最高, 效果最好。

表 3 多种算法处理后序列图像首帧 SCRG 指标

	CNN	RCNN	Faster RCNN	YOLO	Proposed
序列 1	9.06	11.93	11.26	14.91	29.37
序列 2	5.96	5.31	11.61	13.85	43.79
序列 3	8.53	13.50	12.30	12.91	18.38
序列 4	7.52	2.13	13.91	14.64	32.09
序列 5	9.06	11.93	11.26	14.91	29.37
平均	8.03	8.96	12.07	14.24	30.60

定义背景抑制因子 BSF 用于提出算法的性能测试:

$$BSF = \frac{\sigma_m}{\sigma_{out}}$$

σ_{out} 为算法输出图像的局部噪声标准差, σ_m 为算法输入图像的局部噪声标准差。

测试完毕后, 如表 4 所示。CNN、RCNN、Faster RCNN、YOLO 以及提出的算法的平均 BSF 值分别为 1.91、

3.24、144.56、215.70、2 217.73。可见, 提出算法在处理完毕图像后, 背景抑制因子最高, 即对背景的抑制效果最好。

表 4 多种算法处理后序列图像各帧 BSF 指标

	CNN	RCNN	Faster RCNN	YOLO	Proposed
序列 1	2.10	3.49	131.58	213.02	3 937.89
序列 2	1.51	3.67	177.27	209.24	1 108.40
序列 3	0.38	4.92	169.64	200.78	1 152.10
序列 4	3.43	0.57	112.53	242.31	952.13
序列 5	2.10	3.49	131.58	213.02	3 937.89
平均	1.91	3.24	144.56	215.70	2217.73

综上所述, 通过海天线检测、尺度匹配策略、融合算法及图像感兴趣区域选定方法, 提出的算法在小目标检测的精度和效率方面都优于其他检测器。

另外, 为进一步评估提出方法的目标检测性能, 采用受试者工作特性曲线 (ROC), 实验结果如图 4 所示, 可见, 在相同的虚警率下, 本文提出算法的检测率最高, 证明了在 ROC 曲线下的提出算法性能优势。




图 4 ROC 曲线对比图

6 结束语

针对传统策略无法准确检测小目标的问题, 设计一种新的策略, 通过多层尺度与纵横比, 更好反映特征层之间准确的关系, 并捕获小目标。基于新设计的尺度, 新纵横比极大减少了框数, 提高了算法检测速度。另外, 还引入了自适应融合模块, 通过融合特征以及不同的接收域来增加小目标周围的上下文信息。通过海天线处理, 按照感兴趣区域的方法, 在图像中去除了冗余背景, 在更大范围内对算法进行训练。实验结果表明, 与其他检测方法相比, 提出的方法在检测速度和检测精度方面表现良好。

参考文献:

[1] 朱含露, 张旭中, 陈 忻, 等. 基于纵横多尺度灰度差异加权双边滤波的弱小目标检测 [J]. 红外与毫米波学报, 2020, 39 (4): 513-522.

[2] 杨其利, 周炳红, 郑 伟, 等. 基于全卷积递归网络的弱小目标检测方法 [J]. 光学学报, 2020, 40 (13): 1310001-

- 1310002.
- [3] 庞晨涛, 顾寄南. 基于视觉传感器的动态目标位姿估计 [J]. 电子测量技术, 2020, 43 (18): 107-111.
- [4] 邱云志, 汪延华, 余武清. 模糊支持向量机研究综述 [J]. 赣南师范大学学报, 2020 (3): 26-32.
- [5] 沈 鹏, 宋 广, 周钰鑫. X 波段 RCS 跟踪测量系统不确定度分析 [J]. 电子测量技术, 2019, 42 (7): 59-62.
- [6] 马一凡. 复杂光照环境下的单目视觉位姿测量技术研究 [D]. 济南: 山东大学, 2019.
- [7] 王华兵, 万烂军. 基于 Contourlet 及目标特性分析的弱小红外目标检测 [J]. 电子测量与仪器学报, 2019, 33 (3): 120-125.
- [8] 张慧娟, 熊 芝, 劳达宝, 等. 基于 EPNP 算法的单目视觉测量系统研究 [J]. 红外与激光工程, 2019, 48 (5): 517001-517005.
- [9] 劳达宝, 张慧娟, 熊 芝, 等. 基于单目视觉的姿态自动测量方法 [J]. 光子学报, 2019, 48 (3): 315001.
- [10] 蔡如华, 杨 标, 吴孙勇, 等. 弱目标箱粒子标签多伯努利多目标检测与跟踪算法 [J]. 红外与毫米波学报, 2019, 38 (2): 234-244.
- [11] 钟 雷, 李 勇, 牟之英, 等. 未知强杂波下基于 DP-TBD 的雷达弱目标检测 [J]. 系统工程与电子技术, 2019, 41 (1): 43-49.
- [11] ARKIN E, YADIKAR N, MUHTAR Y, et al. A survey of object detection based on CNN and transformer [C] //2021 IEEE 2nd International Conference on Pattern Recognition and Machine Learning (PRML), IEEE, 2021: 99-108.
- [12] 马 睿, 周伍光, 邹应全. 基于传统图像处理算法和 YOLOv4 的水位识别方法研究 [J]. 计算机测量与控制, 2022, 30 (7): 219-225.
- [13] 叶树芬, 施振华, 苏成悦, 等. 基于 YOLOv5 的电力线和杆塔实时检测算法研究 [J]. 计算机测量与控制, 2022, 30 (11): 77-84.
- [14] 王 银, 王飞翔, 孙前来. 多尺度特征融合车辆检测方法 [J]. 系统仿真学报, 2022, 34 (6): 1219-1229.
- [15] 郭宇阳, 胡伟超, 戴 帅, 等. 面向路侧交通监控场景的轻量车辆检测模型 [J]. 计算机工程与应用, 2022, 58 (6): 192-199.
- [16] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design [C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 13713-13722.
- [17] TAN M, PANG R, LE Q V. EfficientDet: Scalable and efficient object detection [C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 10781-10790.
- [18] LIU S, QI L, QIN H, et al. Path aggregation network for instance segmentation [C] //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 8759-8768.
- [12] HAMEL T, SAMSON C. Riccati observers for the nonstationary PnP problem [J]. IEEE Transactions on Automatic Control, 2018, 63 (3): 726-741.
- [13] CAI M, LI Z, SUN H, et al. Satellite pose estimation via single perspective circle and line [J]. IEEE Transactions on Aerospace and Electronic Systems, 2018, 54 (6): 3084-3095.
- [14] 车 鑫, 贾 平, 田大鹏. 机载光电载荷视轴指向控制技术综述 [J]. 光学精密工程, 2018, 26 (7): 1642-1652.
- [15] 冯小雨, 梅 卫, 胡大帅. 基于改进 Faster R-CNN 的空中目标检测 [J]. 光学学报, 2018, 38 (6): 615001-615004.
- [16] 刘德鹏, 李正周, 曾靖杰, 等. 基于多尺度局部对比度和多尺度梯度一致性的红外弱小目标检测算法 [J]. 兵工学报, 2018, 39 (8): 1526-1535.
- [17] 王秀艳. 基于 SVD 矩阵算法的船舶甲板变形监测研究 [J]. 舰船科学技术, 2018, 40 (7A): 19-21.
- [18] 户盼鹤, 鲍庆龙, 陈曾平. 基于概率直方图的被动雷达弱目标检测方法 [J]. 系统工程与电子技术, 2018, 40 (6): 1227-1232.
- [19] 张 秦, 方志耕, 蔡佳佳, 等. 基于广义灰色激励因子的多源不确定性指标动态综合评价模型研究 [J]. 系统工程与电子技术, 2018, 41 (3): 586-593.
- [20] 焦 萍, 姜 威, 贲晔焯, 等. 基于灰度共生矩阵的自动聚焦算法 [J]. 光学技术, 2018, 44 (3): 273-277.
- [19] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C] //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, New York: IEEE Press, 2018: 7132-7141.
- [20] WOO S, PARK J, LEE JY, et al. Cbam: Convolutional block attention module [C] //Proceedings of the European Conference on Computer Vision (ECCV), 2018: 3-19.
- [21] 王勤力, 吴秉国, 朱普芬, 等. ECA-Net: Efficient channel attention for deep convolutional neural networks [C] //Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 11534-11542.
- [22] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C] //2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), IEEE Computer Society, 2017.
- [23] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multi-Box detector [C] //European Conference on Computer Vision, 2016: 21-37.
- [24] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. Scaled-YOLOv4: scaling cross stage partial network [C] //Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 13024-13033.
- [25] MA N, ZHANG X, ZHENG H T, et al. ShuffleNet V2: practical guidelines for efficient CNN architecture design [C] //European Conference on Computer Vision, Springer, Cham, 2018.
- [26] HOWARD A, SANDLER M, CHEN B, et al. Searching for mobileNetV3 [C] //2019 IEEE/CVF International Conference on Computer Vision (ICCV), 2019: 1314-1324.

(上接第 33 页)