

DOI: 10.19650/j.cnki.cjsi.J2107528

面向无人艇的航海雷达与光电吊舱协同环境感知方法^{*}

吴鹏, 孙备, 苏绍璟, 李思达, 左震
(国防科技大学智能科学学院 长沙 410072)

摘要: 为了提升无人艇对典型水面小目标的感知能力, 本文对面向无人艇的航海雷达与光电吊舱协同环境感知方法进行了研究。首先, 本文采用了高斯滤波和形态学滤波进行航海雷达图像处理; 其次, 本文研究了深度学习目标检测算法, 提出了基于多尺度卷积融合结构和空间注意力加强的改进型单个深层神经网络(SSD)目标检测算法模型, 提升对弱纹理小目标特征保持性, 并在VOC2007数据集和典型水面场景下进行了验证。此外, 本文提出了航海雷达与光电吊舱联合目标感知流程, 对航海雷达感知目标分布图和光电吊舱感知目标分布图进行融合处理, 得到最终的目标分布图, 包括目标类别、方位、距离等信息。实验表明, 本文的改进算法达到75.3%的平均准确率(mAP), 同时保持了64.4 FPS的实时检测速度, 航海雷达与光电吊舱能协同有效地对海面目标进行探测。

关键词: 航海雷达; 光电吊舱; 目标检测; 协同感知; 无人艇

中图分类号: TP391.4 TH701 **文献标识码:** A **国家标准学科分类代码:** 510.4050

Cooperative environment perception method for nautical radar and photoelectric pod facing to unmanned surface vehicles

Wu Peng, Sun Bei, Su Shaojing, Li Sida, Zuo Zhen

(College of Intelligence Science and Technology, National University of Defense Technology, Changsha 410072, China)

Abstract: In order to improve the perception ability of Unmanned Surface Vehicles (USV) to typical small water surface targets, cooperative environment perception method for nautical radar and photoelectric pod facing to Unmanned Surface Vehicles is studied in this paper. Firstly, Gaussian filtering and morphological filtering are used to process the image of the nautical radar; Secondly, the deep learning target detection algorithm is studied and an improved single shot multibox detector (SSD) target detection algorithm model is proposed based on multi-scale convolution fusion structure and spatial attention enhancement. The improvement was designed to improve the feature retention of small target with weak texture. The proposed method was verified in the VOC207 data set and typical water surface scene. In addition, the paper proposes the flow chart of joint target perception with nautical radar and photoelectric pod. The perception target distribution maps of nautical radar and photoelectric pod are fused to get the final target distribution map, which includes the information such as categories, orientations, distances, etc. of the targets. The experiment shows that the improved algorithm reaches the mean average precision (mAP) of 75.3% and maintains the real-time detection speed of 64.4 FPS. Besides, the nautical radar and photoelectric pod can detect the sea target cooperatively and effectively.

Keywords: nautical radar; photoelectric pod; object detection; cooperative perception; unmanned surface vehicle

0 引言

水面无人艇(unmanned surface vessel, USV)作为水面无人系统和作战平台的代表性装备,在国防和经济发

展方面具有重要意义^[1]。在军事领域,无人艇可配备自主巡航系统,执行军事探查与监视任务。此外,由于其高速机动性和快速反应能力,无人艇可作为水面侦察装备,有效弥补星载、机载侦察系统以及水下潜航器侦察系统不足,在巡逻、导航、排雷、反潜等领域有着巨大的应用价

收稿日期:2021-02-23 Received Date: 2021-02-23

^{*} 基金项目:湖南省自然科学基金(2020JJ5672)项目资助

值。在民用领域,不论在内河还是海洋,无人艇均可以进行资源探测和夜间水面监测以缓解水上工作人员的压力,在发生自然灾害时也可以执行水上救援,物资输送等任务。

准确可靠的对海面目标环境进行探测是无人艇自主感知、决策的基础。通常,受复杂水面的浪涌、水雾以及阳光反射等因素影响,海面目标呈现尺度小、形变大、纹理弱等特点,如何实现实时精准的检测,提升无人艇视觉感知综合性能,是一项兼具挑战与实际意义的事情。通过携带多种传感器,无人艇可对水面、水下目标及障碍物进行检测识别,为执行各类任务提供重要支撑。无人艇侦察系统的基本组成,通常包括可见光、红外、激光测距、航海雷达等关键传感器。由于单一传感器可观测性的局限性,单独采用雷达或光电吊舱实现海面目标的准确感知跟踪是非常困难的。雷达作为一种主动无线电侦察设备,具有全天候、全天时工作的优点,但缺点是无法对目标成像,目标的判定相对困难,细节分辨率能力不够。而光电吊舱作为一种光电探测设备,具有能成像、细节分辨率能力强的优势,缺点是受能见度的影响较大,视场范围不够宽。因此,实现光电传感器和雷达传感器的联动融合,有效地把雷达和光电传感器的使用同步起来,将大大提高海面目标的探测效率。

1 水面无人艇环境感知研究现状

1.1 无人艇研制方面

近年来,世界各国相继开展了大量水面无人艇的研制工作。其中,美国和以色列在相关技术上一直处于领先地位,并有相关型号列装部队使用^[2],我国无人艇研究虽起步较晚,但发展迅速,目前已研制出多款型号的无人艇。

目前,美军已相继研发了数十种型号的 USV 用于任务测试及部队部署,其中“斯巴达侦察兵 (SPARTAN SCOUT)”和“海狐 (SEAFOX MKII)”已正式服役^[3]。2014 年 8 月,美国海军在詹姆斯河测试了其 13 艘无人艇的“蜂群”作战系统,成功的完成了作战护航任务。以色列在 USV 研发和应用领域也处于世界先进水平,已研发多款 USV 并投入使用。其中“保护者 (Protector)”是全球第一代参与实战的 USV,该型号已被美国和新加坡军方采购。2014 年,以色列推出了搭载自动导航和自动防撞系统的新型 USV“KATANA”^[4]。

我国无人艇起步较晚,2008 年我国生产了第一艘海上无人探测船“天象一号”,主要用于气象探测领域。近年来,国内许多机构都开展了无人艇的相关研究工作,2013 年,由上海大学和上海海事测绘中心等机构联合研发设计了一款“水面无人智能测量平台工程样机”,具有

完全海面自主航行能力,能够极大提高复杂海面测量能力。2014 年,上海大学在中国珠海航展参展的“精海”号无人艇配备北斗导航系统,具有自主定位和规避障碍能力,并在南海开展了测量和巡逻等简单任务。如图 1 所示,为国内外典型无人艇。



图1 国内外典型无人艇

Fig. 1 Typical unmanned surface vehicles at home and abroad

1.2 雷达环境探测

精准广域的环境探测,是保证无人艇安全航行、执行任务的关键,海洋环境复杂、干扰目标多,无人艇的自主巡航难度大,对水面环境目标的智能感知提出了新的挑战。无人艇常常搭载雷达对海面环境进行探测,其中激光雷达和航海雷达是常用的两种雷达。表 1 为激光雷达和航海雷达探测方法比较。

表1 激光雷达与航海雷达水面环境探测方法比较

Table 1 Comparison of water surface environment detection methods between lidar and nautical radar

雷达探测方法	描述
激光雷达探测	探测距离较近,100 m 左右有效距离,目标成像信息丰富,常用于无人艇近距离水面航行避障。
航海雷达探测	探测距离远,5 km 左右有效距离,常用于广域水面环境感知,常常结合电子海图进行远距离探测海面目标方位、距离。

激光雷达是用激光束作为信息载体的雷达系统,是一种主动探测装,其回波信号包含光强、频率、偏振、相位等多种信息,可以获取更多目标物的信息。激光雷达测量精度高,不但可以获取目标的距离、方位、速度信息,用来航行避障,而且还能够获取目标本身的三维轮廓信息,用来进行目标检测与识别。由于传感器的限制,其检测距离较近,且在无人水面艇剧烈晃动时会出现丢失目标的情况。

航海雷达是装在船上用于航行避让、船舶定位、狭水道引航的雷达,通常由天线、发射机、接收机、显示器和电源5部分组成。航海雷达是USV必须配备的传感器,具有探测范围大、受海况和天气条件影响小的优点。

1) 激光雷达探测

利用三维激光雷达对水面环境进行探测,得到的数据不能在无人艇中直接用于检测障碍物,需对数据做后续处理。以Velodyne64线激光雷达为例,该激光雷达每一圈最多采集13.3万个三维数据点,由于水面不反射激光,水面场景点云量一般不超过5万。另外,由于激光采集到的点云是无序点云,对激光点云的寻址读取更加耗时,常用的做法是将三维点云投影到二维栅格平面,对数据进行降维,然后基于栅格平面做数据处理、目标检测识别。利用点云数据进行检测与识别通常分为目标分割与目标识别两部分,而对于目标分割,又分为点云滤除及目标聚类两部分^[5]。

虽然激光雷达具有分辨率高、抗干扰能力强、体积小等优势,但是针对激光雷达在水面环境的图像处理算法以及激光雷达与水面机器人结合的避障算法研究还不多,存在激光雷达图像处理不够贴近实际航行环境,没有考虑水面孤立点以及航行安全距离的问题。

2) 航海雷达探测

航海雷达图像与光学图像在本质上都是能量的平面或空间分布图,但雷达波的传输过程及回波显示方式都与普通光学图像不同,即使与原理相似的激光雷达图像和声呐图像也有诸多不同^[6]。图2为选取在某海湾实际采集的典型航海雷达图像,分别为远海场景图像,港口内自主出港试验雷达图像,近岸雷达图像和桥墩处的雷达图像。




图2 典型航海雷达图像

Fig. 2 Typical nautical radar images

航海雷达图像具有如下特点:

1) 与光学图像相比,雷达图像数据组成相对简单。雷达图像是灰度图像,主要由灰度级较高的目标区(陆地、礁石和船舶等)和灰度级较低黑色背景区组成。

2) 雷达图像中存在大量噪声干扰,包括外部环境干扰(雨雪、海浪和同频干扰)、内部噪声以及图像经过采集和保存后添加的噪声。

3) 同一帧内的不同目标根据回波强弱其亮度可能不

同;不同帧的同一目标外形可能出现变化。

4) 由于雷达自身的移动会造成图像中目标的位置和角度变化,需要对GPS和惯导数据进行融合来解决运动背景下的目标检测和跟踪问题。

本文主要针对远距离目标探测任务,因此本文重点研究基于航海雷达的环境探测。

1.3 深度学习目标检测算法

深度学习因其强大的特征提取和自学习能力,已被广泛应用在视觉检测的各个领域。然而,由于深度学习检测器主要依靠浅层卷积提取小目标信息,而浅层卷积的语义特征往往不是很丰富,因此,深度学习算法针对海面场景的小尺寸、弱纹理目标的检测效果较有限^[7]。图3为典型水面场景小目标示例。




图3 典型水面场景小目标示例

Fig. 3 Examples of small targets in typical water surface scenes

深度学习目标检测算法根据其策略差异,常分成基于区域提出的目标检测算法和基于回归的目标检测算法两类。前者典型代表为Faster R-CNN^[8],后者典型代表为YOLO^[9](you only look once)和单个深层神经网络(single shot multibox detector, SSD)^[10],3种方法的对比如表2所示。

表2 典型深度学习目标检测算法对比

Table 2 Comparison of typical deep learning target detection algorithms

算法	描述
Faster R-CNN	利用区域提出网络代替选择性搜索算法进行候选区域提出,实现了端到端训练,加快了检测速度。
YOLO	基于网格直接回归目标信息,检测速度快,适合实时性任务需求。
SSD	结合了Faster R-CNN的锚框和YOLO的回归思想,很好地权衡了检测速度和精度,同时引入了多尺度检测方法,对密集目标和小目标十分友好。

1) Faster R-CNN 算法

Faster R-CNN是典型的基于区域提出的目标检测架构,其主要特点是区域生成网络(region proposal network,

RPN)取代了选择性搜索算法,极大地提升了目标检测效率。

快速区域生成卷积神经网络(faster region-based convolution neural networks, Faster R-CNN)中候选区域提出和特征聚合部分共用一个基础网络,该网络的输出特征图传入到RPN中得到一系列候选区域,然后映射候选区域基础网络的输出特征图上,而不再需要对每个候选区域重复提取特征。RPN用到了锚框(anchor box)的思想,锚(anchor)可理解为在特征图上预设的一组不同大小和长宽比的默认框。Faster R-CNN基本形成了基于区域提出的目标检测算法的基础架构,初步实现了端到端训练,可用于工业领域的实时性部署,但检测速度依然较慢。

2) YOLO 算法

YOLO将目标的检测和识别都转换成回归任务,大幅提升了检测速度。YOLO采用了一种相对简单的架构,将特征图分为 7×7 的网格后,直接对对应的98个默认框进行回归,即每个网格回归两个目标。其回归过程为:提取到 7×7 特征图后,利用全连接层聚合信息,然后回归出整个图像中的所有目标信息。回归结果用一个 $7 \times 7 \times 30 (B \times 5 + C)$ 的张量进行表示, $B=2$ 表示每个网格回归两个目标, $C=20$ 表示预测的目标类别。

YOLO最大的优势即非常高的检测效率,由于使用了全局信息进行回归,漏检和误检的情况相对较少,但因为并未引入多尺度信息,在处理密集目标或小目标时显得有些笨拙。只使用 7×7 的网格回归也会导致目标的精确定位十分困难,严重影响其检测精度。

3) SSD 算法

SSD使用在数据集ILSVRC CLS-LOC上训练好的VGG16作为骨干网。SSD在6个层次特征图上执行多尺度检测, 3×3 的卷积核被用来直接对8732个不同尺度的默认框对应的目标位置和类别信息进行预测。SSD直接利用卷积神经网络的多层次特征执行多尺度目标检测,避免了图像金字塔导致的特征重复提取,计算资源占用少,检测速度更快。但是,SSD利用多层次特征图独立执行检测,不同级别之间的有效信息缺乏有效的交互,特征重用性不好。

综合对以上3种算法的分析和小目标检测需要,本文采用SSD检测架构作为基础框架并进行改进,理由如下:1)本算法需要在嵌入式平台进行部署并要求具有一定的实时性,排除基于候选区域提出的深度学习算法;2)SSD具有较高的检测精度,同时兼顾了检测速度;3)SSD采用的多尺度检测算法对密集目标和小目标场景适应性更强。

2 航海雷达目标探测

图像滤波是航海雷达图像处理常用的方法。通过高斯滤波可以抑制雨雪杂波、海杂波、内部噪声对目标提取时的影响,提高目标探测的准确度;形态学滤波可以对图像形状和结构的分析及处理,包括图像分割、特征抽取、边界检测、图像滤波、图像增强和恢复工作^[11]。

2.1 高斯滤波

航海雷达的工作过程中,雷达图像可能会被杂波干扰,包括雨雪杂波、内部噪声等,在对雷达图像进行目标检测前,需要对雷达图像做滤波处理,更好地显示目标的轮廓特征,便于目标探测。

高斯滤波是一种线性平滑滤波,适用于消除高斯噪声。高斯噪声是指它的概率密度函数服从高斯分布(即正态分布)的一类噪声。如果一个噪声,它的幅度分布服从高斯分布,而它的功率谱密度又是均匀分布的,则称它为高斯白噪声。

高斯滤波器是一类根据高斯函数的形状来选择权值的线性平滑滤波器。高斯平滑滤波器对于抑制服从正态分布的噪声非常有效,一维零均值高斯函数为:

$$G(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{x^2}{2\sigma^2}} \quad (1)$$

其中,高斯分布参数 σ 决定了高斯函数的宽度。对于图像处理来说,常用二维零均值高斯函数作平滑滤波器,二维高斯函数为:

$$G(x, y) = \frac{1}{\sqrt{2\pi}\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (2)$$

高斯滤波器是根据高斯函数的形状来选择权值的线性平滑滤波器,简单来说就是根据高斯分布得到高斯模板然后做卷积相加的一个过程,其具体过程为^[12]:

- 1) 移动相关核的中心元素,使它位于输入图像待处理像素的正上方;
- 2) 将输入图像的像素值作为权重,乘以相关核;
- 3) 将上面各步得到的结果相加做为输出。

图4为图像平滑后的结果图,由于原图像包含的噪声信息较少,经过滤波处理后的雷达图像目标的边缘更加清晰。

2.2 形态学滤波

数学形态学是分析几何形状和结构的数学方法,它是由一组形态学的代数运算符组成的,最基本的形态学运算符有:腐蚀(erosion)、膨胀(dilation)、开(opening)和闭(closing)^[13]。本文采用闭运算对航海雷达图像做简单处理,将独立目标与岸边、桥墩等成片区域分离,用来




图 4 高斯滤波结果图

Fig. 4 Result images of Gaussian filtering

突出单个目标。闭运算将需要先执行膨胀操作,再执行腐蚀操作。膨胀是形态学的重要算子之一,图像膨胀可以对图像中的空洞进行填充,也可以使关心的目标更加醒目,腐蚀则正好相反。如图 5 所示,为闭运算的流程示意图。经过闭运算处理后,灰色区域所占像素增加,经过腐蚀操作后,灰色区域所占像素减少,但与原图相比,灰色区域仍多两个像素。




图 5 闭运算原理流程图

Fig. 5 Closing operation principle flow chart

如图 6 所示,为航海雷达图像形态学滤波处理前后,以出港场景图像为例,岸边区域经过滤波处理后被连成一体,单个目标被突出显示,有利于得到目标距离、方位,进而对目标进行筛选及目标特性分析。




图 6 航海雷达图像形态学滤波处理前后

Fig. 6 Before and after the morphological filtering processing of nautical radar images

3 基于改进 SSD 的深度学习目标检测算法

SSD 在算法设计上吸取了 Faster R-CNN 的锚点机制和 YOLO 算法的回归思想,兼顾了检测速度和精度,同时创新性的引入了多尺度思想。为了提高目标检测算法对小目标的检测性能,本文对 SSD 算法进行改进。

3.1 改进的 SSD 检测算法

本文在 SSD 网络结构的设计上,综合采用更大的 75×75 的特征图并设置更小更密集的默认框,同时采用特征融合和注意力机制来增强特征提取过程。利用特征融合模块和空间注意力模块,本文设计了一个新的改进的 SSD 算法。改进后的 SSD 结构示意图如图 7 所示。为了增强小目标检测的性能,与 SSD 相比,本文同时在 75×75 的特征图上进行检测。conv4_3 和 conv7 的输出特征图上采样后分别与 conv3_3 和 conv4_3 进行拼接。通过多层卷积来充分融合多尺度特征。通过将 5 个空间注意力模块插入网络,用于增强重要的空间区域。




图 7 改进后的 SSD 算法结构示意图

Fig. 7 Schematic diagram of the improved SSD algorithm structure

在预测层的设计中,本文添加了 7 个预测层以对 7 个尺度的特征图进行预测。对于通道数为 p 的 $w \times h$ 特征图,本文应用 $3 \times 3 \times p$ 的卷积核对 $w \times h$ 特征图进行逐像素预测。每个预测层包含两个卷积层,分别用于预测目标类别和位置偏移。输出通道设置为 $a \times c$ 和 $a \times 4$,其中“ a ”代表特征图每个像素处预置的锚框数量,“ c ”代表目标类别的数量,“4”代表位置参数的数量。预测后,在推理过程中应用非极大值抑制过滤掉重复多余的预测框,并保存得分最高的 200 个预测框。

3.2 检测效果

本节首先在 VOC2007 数据集上进行训练和测试,此外,通过搭建真实海域数据集,来检验算法性能。

算法基本参数如下:输入图像的大小为 300×300 ,总迭代次数为 12 万,每次迭代处理 32 张图像,初始的学习率为 10^{-3} ,训练 8 万步时调整为 10^{-4} ,训练 10 万步时调整为 10^{-5} ,直至训练结束。优化器采用 SGD 优化器,初始化方法采用 Xavier 初始化方法。本文利用搭载 NVIDIA 显卡的深度学习服务器进行模型训练与调试,其软硬件配置情况如表 3 所示。

表 3 服务器软硬件配置

Table 3 The configuration of the server hardware and software

硬件配置	CPU: Intel Core i9-10900X CPU @ 3.70G Hz 内存: 64 G 显卡: TITAN RTX 24G×2
软件配置	系统: Ubuntu 16.04 LTS 深度学习框架: Pytorch 1.2.0, torchvision 0.2.0 深度学习支持: CUDA 10.1, cudnn 7.3.2 编译器: Pycharm 2019 其它: python 3.7, matplotlib 3.3.2

1) VOC 数据集检测结果

表 4 展示了原始 SSD 版本与本文改进方法的精度和推理速度对比。本文方法在 TITAN RTX GPU 上对输入尺寸为 300×300 的图像进行推理时,可以实现 45.3 FPS 的实时检测速度。为了公平地比较改进前后的推理速度,本文在相同的参数设置下测试了原始 SSD 版本,其检测速度为 69.7FPS。由于添加了更多的结构,本文方法比 SSD 慢 35%。但是,本文所提方法在 300×300 的输入下达到了 79.3% 的 mAP,比 SSD 性能高出 1.6 个百分点,与 SSD512* 相当,本文方法在精度方面具有明显优势。

为了更直观地对比改进前后算法的检测结果,本文对检测结果进行了可视化。图 8 显示了本文的改进算法与 SSD 算法在 PASCAL VOC2007 测试集上的检测

表 4 基于 PASCAL VOC2007 的模型精度和速度对比
Table 4 Comparison of model accuracy and speed based on PASCAL VOC2007

方法	mAP	FPS	GPU	输入尺寸
SSD300* ^[10]	77.5	46	Titan X	300×300
SSD512* ^[10]	79.5	19	Titan X	512×512
SSD300	77.7	69.7	TITAN RTX	300×300
本文方法	79.3	45.3	TITAN RTX	300×300

结果对比,置信度阈值设置为 0.6。与 SSD 相比,本文的模型体现了更优异的检测性能。在 6 组图片中,本文改进后的算法能更好地区分目标间存在的重叠和遮挡,将近距离的两个物体进行了有效的区分检测,例如第 1 组中的猫,第 2 组人身后的牛和第 3 组和第 4 组中的人。在后两组图像中,本文算法在目标密集的场景中能检测出更多的目标。



图 8 改进算法与原始 SSD 的检测结果对比

Fig. 8 Comparison of the detection results between the improved algorithm and original SSD

检测率定义为检测出的目标占实际目标数量的比例,虚警率定义为预测错误的边框数量占有所有预测边框的比例。表 5 中结果表明,改进后算法在虚警率要求一致的情况下检测率高于 SSD 检测算法。当虚警率为 5%, 10% 和 20% 时,本文改进算法的性能分别优于 SSD 1.1%, 2.3% 和 2.5%。

2) 湛江海试场景检测结果

为了进一步评估模型的性能,本文基于典型海面场景数据集设计了实验,本课题建立了典型海面场景目标数据集用于验证本文算法在实际场景中的应用效果。本数据集通过实验采集和人工手动标注的方式建立,类别包括“渔船(boat)”“桥墩(pier)”“水鼓(drum)”“浮标(buoy)”。数据集共包含 1 200 张图像,3 901 个标注目标,原始图像的尺寸为 $1\,920 \times 1\,080$ pixel。其中 1 000 张图像用于训练,200 张图像用于测试。

表 5 虚警率为 0.05,0.1 和 0.2 时的检测精度
Table 5 The detection accuracy when false alarm rate is 0.05, 0.1 and 0.2

虚警率	方法	检测率
0.05	SSD	0.462
	本文改进方法	0.473
0.10	SSD	0.553
	本文改进方法	0.576
0.20	SSD	0.641
	本文改进方法	0.666




图 9 精度与召回率关系曲线
Fig. 9 Relationship curve of accuracy and recall

测试时,本文使用了 200 张测试集的图像,测试前图像尺寸调整为 300×300。图 9 显示了 3 个模型的准确率与召回率关系曲线,表 6 为对应的检测速度和精度。

实验结果表明,本文的改进算法达到 75.3%的 mAP,同时保持了 64.4 FPS 的实时检测速度,本文的特征融合模块和空间注意力模块在增强浅层方面表现良好,能提

表 6 在典型海面场景数据集上的速度和精度对比
Table 6 Comparison of speed and accuracy on typical sea surface scene data set

方法	mAP	FPS
SSD	67.3	67.6
本文改进方法	75.3	64.4

高检测准确度。图 10 为本文改进算法的典型海面目标检测效果图。




图 10 典型海面目标检测效果
Fig. 10 Typical sea surface target detection effect

4 航海雷达与光电吊舱的联动协同目标探测流程

4.1 雷达引导光电吊舱

雷达和光电传感器联动,一种常用的方法是,雷达扫描发现目标后,雷达将把目标的距离、方位和运动方向等信息等打包传输给光电传感器,引导光电系统光轴转向目标位置,以便进一步的细节分析和判断,由光电传感器对可疑目标进行探测,判定其类别、危险性等。同时雷达将数据信息传送到控制中心,光电传感器根据雷达传过来的方位角信息确定需要转动的转角,转到相应位置,将目标的方位角、高低角和视频图像传到控制中心;控制中心对收到的信息进行研判,做出对可疑目标是否采取行动的决策。可实时引导光电的光轴指向目标,而且这种方式不存在多目标队列问题,可根据图像对任意目标按任意顺序进行引导,大大提高了雷达引导的效率和方便性,实现了真正意义上的雷达引导^[14-15],示意图如图 11 所示。

4.2 雷达与光电联合标定

在实际环境中,雷达引导光电适用于目标较少的场合,即雷达探测后得到的目标方位列表中,目标个数较少时,光电吊舱可以遍历目标方位列表对目标进行检测识别。当水面环境目标较多且噪声点更密集时,目标方位列表中的目标个数较多,光电吊舱去遍历目标方位列




图 11 雷达引导光电吊舱的流程图

Fig. 11 Flow chart of radar guided photoelectric pod

表时将会花费大量时间,造成很大延迟和滞后。针对这种情况,需要采用雷达与光电的联合标定方法,即航海雷达与光电吊舱同步进行环境感知、结果融合。雷达具有扫描周期,假设周期为 T_1 ,则扫描角速度为 w_1 ,并且有

$$w_1 = \frac{2\pi}{T_1} \quad (3)$$

假设光电吊舱的转动周期为 T_2 ,转动角速度为 w_2 ,则有

$$w_2 = \frac{2\pi}{T_2} \quad (4)$$

雷达与光电同步探测的思想为, $w_1 = k \cdot w_2 (k > 0)$,当雷达扫描周期较长时,可将光电吊舱的转动速度设置为相同的角速度,光电吊舱的光轴与雷达的扫描线一致;当雷达扫描周期较短时,可将雷达的扫描速度设置为光电吊舱转动角速度的数倍,两者将探测的结果进行融合,协同对环境进行感知,示意图如图 12 所示。




图 12 航海雷达与光电吊舱联合目标感知示意图

Fig. 12 Schematic diagram of joint target perception with nautical radar and photoelectric pod

5 实验结果

本文在实际海面环境下开展了实验测试,实验平台如图 13 所示,航海雷达安装在距离海平面 2.5 m 高度,吊舱距离海平面 1 m,光电吊舱具有可见光相机、红外成像仪、激光测距仪 3 种光学传感器。本次实验在 1 级海况下进行,海域范围为 3 km×3 km,实验时,航海雷达与光电吊舱均按照 0.785 rad/s 的扫描与转动。在实验开始前,采用角度校准装置对航海雷达与光电吊舱的 0° 方向进行校准对齐。

本文的雷达图像处理与过滤,视觉目标检测算法部署在 NVIDIA Xavier 嵌入式计算平台中,平台实物图如图 14 所示。该嵌入式图像处理平台每秒运算量高达 32 万亿次,广泛应用于深度学习和计算机视觉任务。

NVIDIA Xavier 的强劲性能得益于其丰富的板载资源,如表 7 所示。该平台可以同时运行多种算法,能有效保障无人艇多任务的高效执行。在高水平的实时处理性能支持下,无人艇可以高效地接收多传感器的环境感知和岸上平台发送的控制指令,信息感知其环境、检测识别相关水面目标。




图 13 实验平台示意图

Fig. 13 Schematic diagram of the experiment platform



图 14 NVIDIA Xavier 嵌入式图像处理平台实物图

Fig. 14 Picture of the NVIDIA Xavier embedded image processing platform

表 7 NVIDIA Xavier 板载资源
Table 7 NVIDIA Xavier onboard resources

GPU	512-Core Volta GPU with Tensor Cores
深度学习加速器	(2x) NVDLA Engines
CPU	8-Core ARM v8. 2 64-Bit CPU, 8 MB L2 + 4 MB L3
内存	16 GB 256-Bit LPDDR4x 137 GB/s
存储	32 GB eMMC 5. 1
视觉加速器	7-Way VLIW Vision Processor
编解码	(2x) 4Kp60 HEVC/(2x) 8Kp30 12-Bit Support
摄像头	(16x) CSI-2 Lanes
PCIE/SLVS/USB/UFS	(8x) PCIe Gen4 / (8x) SLVS-EC (3x) USB 3. 1 Single Lane UFS
连接	Gigabit Ethernet

采用雷达与光电吊舱同步的方式对环境进行探测,实验时,航海雷达与光电吊舱均按照 0. 785 rad/s 的扫描与转动,光电吊舱的可见光相机视场角设置为 10°,检测帧数约为 11 FPS。通过该种方式,可对环境进行准确感知。

如图 15 所示,为实验环境中雷达与光电吊舱协同探测结果图,采用雷达引导光电吊舱的方式对海面目标进行确认,最终得到目标相对船艏向的角度为 76. 289°,距离为 188. 086 m,并可计算出目标的经纬度为 (110. 416 54°E, 21. 261 44°N)。



发现目标|角度: 76.289°, 距离188.085 m, 经纬度(110.416 54°E, 21.261 44°N)

图 15 实验环境中雷达与光电吊舱联合探测结果

Fig. 15 Joint target perception result of nautical radar and photoelectric pod in experiment environment

6 结 论

本文对面向无人艇的航海雷达与光电吊舱协同环境感知方法进行了研究。首先,本文研究了航海雷达目标探测方法,分析了航海雷达图像特点,采用了高斯滤波和形态学滤波进行航海雷达图像处理;其次,研究了基于光电吊舱的深度学习目标检测算法,提出了基于多尺度卷积融合结构和空间注意力加强的改进型 SSD 目标检测算法,设计空间注意力结构对卷积特征层逐个增强,提升对弱纹理小目标特征保持性,并在 VOC2007 数据集和典型水面场景下进行了验证。此外,本文研究了航海雷达与光电吊舱协同环境感知方法策略,提出了雷达引导光电和雷达与光电联合标定两种流程。实验结果表明,本文的改进算法达到 75. 3% 的 mAP,同时保持了 64. 4 FPS 的实时检测速度,在典型水面场景下,航海雷达与光电吊舱能协同有效的对海面目标进行探测。

无人艇作为水面无人系统的代表性装备,其目标感知能力是无人艇自主航行和行为决策的前提。光电目标检测可和雷达图像有效联合,共同支撑无人艇水面目标感知。未来的研究应当考虑如何在精简网络的基础上提升检测效率;在样本不平衡条件下实现少样本目标稳定感知,并提升模型网络模型的泛化能力等。

参考文献

- [1] 刘士豪. 基于视觉的无人艇环境感知技术研究[D]. 武汉:华中科技大学, 2019.
LIU SH H. Research on vision-based environment awareness technology for unmanned surface vehicles[D]. Wuhan: Huazhong University of Science and Technology, 2019.
- [2] 金霄, 郑开原, 王得朝, 等. 国外军用无人水面艇发展综述[J]. 中国造船, 2020(61): 221-226.
JIN X, ZHENG K Y, WANG D CH. Development of foreign military unmanned surface craft[J]. Shipbuilding of China, 2020(61): 221-226.
- [3] U. S. Unmanned system roadmap: 2007- 2032 [R]. Washington: U. S. Department of Defense, 2007: 43-54.
- [4] 万接喜. 外军无人水面艇发展现状与趋势[J]. 国防科技, 2014, 35(5): 91-96.
WAN J X. The development status and trend of unmanned surface craft in foreign army [J]. National Defense Science and Technology, 2014, 35(5): 91-96.
- [5] 李小毛, 张鑫, 王文涛等. 基于3D激光雷达的无人水面艇海上目标检测[J]. 上海大学学报, 2017, 23(1): 27-36.
LI X M, ZHANG X, WANG W T. 3D Lidar-based marine object detection for USV[J]. Journal of Shanghai University, 2017, 23(1): 27-36.
- [6] 田守东. 基于雷达图像的目标检测技术研究[D]. 哈尔滨: 哈尔滨工程大学, 2010.
TIAN SH D. Research on the technology of target detection based on radar image [D]. Harbin: Harbin Engineering University, 2010.
- [7] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector[J]. IEEE European Conference on Computer Vision, 2016, 10: 21-37.
- [8] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-Time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6): 1137-1149.
- [9] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2016, DOI: 10.1109/CVPR. 2016. 91.
- [10] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector [C]. European Conference on Computer Vision, 2016, DOI: 10.1007/978-3-319-46448-0_2.
- [11] 王海霞, 徐进, 王庆名, 等. 航海雷达目标快速识别方法研究[J]. 无线电通信技术, 2020, 46(1): 126-132.
WANG H X, XU J, WANG Q M, et al. Research on data fusion method of marine radar and electronic chart [J]. Radio Communications Technology, 2020, 46(1): 126-132.
- [12] XU J, WANG H X, CUI C, et al. Oil spill segmentation in ship-borne radar images with an improved active contour model [J]. Remote Sensing, 2019 (11): 1698.
- [13] 张大坤, 罗三明. 形态学中闭运算功能的扩展及其应用[J]. 计算机工程与应用, 2010, 46(27): 185-187.
ZHANG D K, LUO S M. Function extension of morphological closing operation and its application [J]. Computer Engineering and Applications, 2010, 46(27): 185-187.
- [14] 李成美, 白宏阳, 郭宏伟, 等. 一种改进光流法的运动目标检测及跟踪算法[J]. 仪器仪表学报, 2018, 39(5): 249-256.
LI CH M, BAI H Y, GUO H W, et al. Moving object detection and tracking based on improved optical flow method [J]. Chinese Journal of Scientific Instrument, 2018, 39(5): 249-256.
- [15] 任清安, 吕春燕. 雷达光电智能协同探测技术研究[J]. 雷达科学与技术, 2016(14): 173-183.
REN Q An, LYU CH Y. Research on radar and photoelectric collaborative tracking algorithm [J]. Radar Science and Technology, 2016(14): 173-183.

作者简介



吴鹏, 分别于2017年和2019年于国防科技大学获得学士学位和硕士学位, 正在国防科技大学攻读博士学位, 主要研究方向为智能探测和目标感知。

E-mail: pengwu9510@163.com

Wu Peng received his B. Sc. and M. Sc. degrees in 2017 and 2019 both from National University of Defense Technology. Now, he is studying for a doctor degree in National University of Defense Technology. His main research interest include intelligent detection and target perception.



孙备(通信作者), 分别于2012年、2014年和2018年于国防科技大学获得学士、硕士和博士学位, 现为国防科技大学讲师, 主要研究方向为智能探测和目标感知。

E-mail: sunbei08@nudt.edu.cn

Sun Bei (Corresponding author) received his B. Sc., M. Sc. and Ph. D. degrees in 2012, 2014 and 2018 all from National University of Defense Technology. Now, he is a lecturer in National University of Defense Technology. His main research interest includes intelligent detection and target perception.