

海上微弱目标雷达-红外多视角协同智能 TBD 技术

孙殿星^{1,2}, 黄亚圣^{1*}, 彭锐晖^{1,2}, 谭顺成³, 王国宏³

(1. 哈尔滨工程大学信息与通信工程学院, 黑龙江哈尔滨 150000; 2. 青岛哈尔滨工程大学创新发展中心, 山东青岛 266000;
3. 海军航空大学信息融合研究所, 山东烟台 264000)

摘要: 海上微弱目标检测通常面临目标雷达散射截面积小、红外对比度低、易受海杂波、漂浮物、岛礁及海鸟等背景干扰影响的难题, 单一传感器检测方法受自身物理特性限制, 在复杂海况下难以兼顾检测概率与虚警抑制性能. 检测前跟踪(Track-Before-Detect, TBD)技术通过多帧联合处理能够有效提升微弱目标检测能力, 但传统 TBD 方法多依赖先验运动模型, 且主要针对单一传感器场景, 在目标机动或背景复杂条件下适应性不足. 针对上述问题, 本文提出一种雷达-红外多视角协同智能 TBD 技术, 实现复杂海面环境下微弱目标的高可靠检测. 首先, 针对雷达回波中背景杂波和噪声点迹密集的问题, 引入雷达低门限预处理机制, 在保留目标回波信息的同时剔除部分低幅值干扰点迹, 降低后续处理的计算复杂度. 随后, 针对雷达与红外传感器在量测维度和空间表达上的异构性, 构建雷达-红外异构数据空间映射模型, 将雷达距离-方位量测映射至红外像平面, 生成雷达-红外虚拟融合图像, 实现两类传感器信息在统一像素空间内的对齐与融合, 从而提升目标量测数据率并增强目标显著性. 在融合图像构建基础上, 采用最大值多帧累积策略对连续融合图像进行能量叠加, 突出微弱目标的空时相关性并抑制随机噪声. 同时, 利用真实目标在雷达与红外两种传感器中均产生响应, 而部分背景干扰仅在单一传感器中出现的跨模态差异特征, 构建基于雷达-红外响应联合约束的目标潜在区域划定机制, 有效排除海鸟、浮漂等非目标干扰, 为后续检测提供可靠的空域约束, 从而显著降低虚警率. 在目标检测阶段, 针对多帧累积融合图像中微弱目标尺度小、对比度低、航迹呈细长连续分布的特点, 本文基于 YOLOv11 框架构建自适应多尺度特征增强网络(Adaptive Multi-Scale Feature Enhancement YOLOv11, AMSFE-YOLOv11), 实现目标航迹检测与实例分割, 并进一步抑制复杂背景干扰. 该方法摆脱了传统 TBD 对先验运动模型的依赖, 在目标发生机动的情况下仍能够有效提取航迹特征和空时相关性, 实现稳定的能量累积, 具有良好的鲁棒性和适用性. 最后, 基于海上实测雷达与红外数据对所提出方法进行了验证. 结果表明, 该方法对于微弱目标检测概率达到 94.7% 以上, 虚警率为 0.52% 以下, 相较于单一传感器检测方法表现出明显优势, 验证了所提雷达-红外多视角协同智能 TBD 技术在复杂海面环境下的有效性和工程应用潜力.

关键词: 微弱目标检测; 雷达-红外; 多视角协同; 多帧累积; 目标潜在区域; AMSFE-YOLOv11

基金项目: 泰山学者项目(No.tstp20250747)

中图分类号: TN953; TN219

文献标识码: A

文章编号: 0372-2112(2025)12-4686-22

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20250887

Radar-Infrared Multi-View Cooperative Intelligent TBD Technology for Maritime Weak Target Detection

SUN Dian-xing^{1,2}, HUANG Ya-sheng^{1*}, PENG Rui-hui^{1,2}, TAN Shun-cheng³, WANG Guo-hong³

(1. College of Information and Communication Engineering, Harbin Engineering University, Harbin, Heilongjiang 150000, China;

2. Qingdao Innovation and Development Center, Harbin Engineering University, Qingdao, Shandong 266000, China;

3. Institute of Information Fusion, Navy Aeronautical University, Yantai, Shandong 264000, China)

Abstract: Weak maritime target detection usually faces challenges such as small radar cross sections, low infrared contrast, and susceptibility to background interference from sea clutter, floating objects, islands, and seabirds. Due to inherent physical limitations, single-sensor detection methods have difficulty balancing detection probability and false-alarm suppression under complex sea conditions. Track-before-detect (TBD) techniques can effectively enhance weak target detection through multi-frame joint processing; however, traditional TBD methods mostly rely on prior motion model assumptions

and are primarily designed for single-sensor scenarios, showing insufficient adaptability under target maneuvering or complex background conditions. To address these issues, this paper proposes a radar-infrared multi-view cooperative intelligent TBD technique to achieve reliable detection of weak targets in complex maritime environments. First, to deal with the dense background clutter and noise points in radar echoes, a radar low-threshold preprocessing mechanism is introduced, which removes part of the low-amplitude interference points while preserving target echo information, thereby reducing the computational complexity of subsequent processing. Then, considering the heterogeneity of radar and infrared sensors in measurement dimensions and spatial representations, a radar-infrared heterogeneous data spatial mapping model is constructed. Radar range-azimuth measurements are mapped onto the infrared image plane to generate radar-infrared virtual fusion images, enabling the alignment and fusion of the two types of sensor information in a unified pixel space, thus increasing the target measurement data rate and enhancing target saliency. Based on the constructed fusion images, a maximum-value multi-frame accumulation strategy is employed to perform energy accumulation on consecutive fusion images, highlighting the spatio-temporal correlation of weak targets and suppressing random noise. Meanwhile, by exploiting the cross-modal difference that real targets generate responses in both radar and infrared sensors, whereas some background interference appears only in a single sensor, a candidate target region delineation mechanism based on joint radar-infrared response constraints is established. This mechanism effectively excludes non-target interference such as seabirds and floating objects, provides reliable spatial constraints for subsequent detection, and significantly reduces false-alarm rates. In the target detection stage, considering that weak targets in multi-frame accumulated fusion images are characterized by small size, low contrast, and elongated continuous trajectories, an adaptive multi-scale feature enhancement network based on the YOLOv11 framework (AMSFE-YOLOv11) is constructed to achieve target trajectory detection and instance segmentation, while further suppressing complex background interference. The proposed method eliminates the dependence of traditional TBD approaches on prior motion models and can still effectively extract trajectory features and spatio-temporal correlations under target maneuvering conditions, achieving stable energy accumulation with good robustness and applicability. Finally, the proposed method is validated using real maritime radar and infrared data. The experimental results demonstrate that the proposed method achieves a detection probability exceeding 94.7% for weak targets, with a false alarm rate below 0.52%. Compared with single-sensor detection approaches, it exhibits a clear performance advantage, thereby validating the effectiveness and practical application potential of the proposed radar-infrared multi-view cooperative intelligent TBD technique in complex maritime environments.

Key words: weak target detection; radar-infrared; multi-view cooperation; multi-frame accumulation; candidate target region; AMSFE-YOLOv11

Foundation Item(s): Taishan Scholars Program (No.tstp20250747)

1 引言

海上微弱目标检测是目标探测领域的重要研究方向,对海上航行、海上运输以及国防安全等领域都有着重要意义^[1-3]。由于微弱目标回波能量小,在复杂海面背景下极易被杂波、岛屿等背景回波所干扰^[4,5],造成其检测难度大、漏检和虚警率增加。当目标距离较远时,其在红外图像中所占像素较少,与背景的灰度差异不显著。另外,海面漂浮物、海鸥等物体的干扰也会造成虚警和误判。

为提高预警探测系统对海上运动微弱目标的检测性能,检测前跟踪(Track-Before-Detect, TBD)一直都是备受关注的技术路径。TBD方法通过对多帧数据联合处理,能有效利用目标的空时相关性,实现目标能量的累积,从而提升对微弱目标的检测能力^[6]。其中,文献[7]将贝叶斯传播机制用于TBD方法,提出一种基于贝叶斯推理的多帧联合处理的TBD算法。该算法在低信噪比条件下能够实现对目标的有效检测并具有较低的虚警

率,但该方法依赖于目标的运动模型,对于目标机动的情况,其检测性能会有所退化,且对多目标检测能力有限;文献[8]提出基于修正Hough变换的TBD方法,通过多帧共线、速度约束及数据匹配Hough变换,提升杂波抑制与多目标分辨能力,但是对慢动或机动目标的检测能力有限;文献[9]在多伯努利TBD方法中引入Geodesic粒子流以提高后验密度估计精度,并结合航向信息优化航迹合并,从而增强微弱目标在杂波环境下的检测与跟踪性能。但是其检测性能依赖于目标运动模型和航向信息精度,当这些先验条件不够理想时,其检测性能会受到较大影响;文献[10]提出了一种基于精确运动建模与优化函数改进的动态规划TBD算法,该方法在距离-多普勒平面中融合恒加速度与转弯模型,通过递归能量累积与优化路径搜索,提升了机动目标的检测概率与分辨能力,但依然高度依赖于目标运动模型;文献[11]提出了一种基于改进随机Hough变换(Randomized Hough Transform, RHT)的TBD算法,通过

引入基于最小欧氏距离的新投票方法以及更新参数单元来减少轨迹恢复偏差,从而在低信噪比环境下能够更快速地检测微弱目标,但该方法仍依赖于先验速度约束,面对复杂机动目标时适应性不足.通过分析上述文献可知,传统TBD方法对于微弱目标的检测性能高度依赖于目标运动模型的合理性和匹配度.当目标机动时其运动轨迹往往难以预知,导致预设模型的匹配度下降,造成机动目标检测性能恶化.另外,上述方法均是基于单传感器数据的TBD技术,尚不适用于多传感器情况.

随着人工智能技术的不断发展成熟,研究人员逐渐将深度学习算法引入微弱目标检测领域.文献[12]设计了一个名为对象级假警报数量(for Object-Level Number of False Alarms, OL-NFA)的检测头,该检测头通过建模背景分布而非专注于目标特征,提升了YOLO在微弱目标检测中的表现.文献[13]针对遥感图像中小目标密集、尺度多样及背景噪声复杂等问题,提出了一种融合多尺度特征信息的混合锚检测器AEM-YOLO,通过锚框生成改进、解耦检测头设计及自适应增强模块,有效提升了微弱目标检测性能.文献[14]针对航拍图像中微弱目标检测效率低、精度差的问题,提出了一种改进RT-DETR的检测算法,结合CCFM-P2ASF尺度特征融合模块有效增强了微弱目标感知能力.上述方法能够基于深度学习技术挖掘单帧目标特征,提高微弱目标检测性能,但是没有利用目标空时相关性实现多帧能量累积.文献[15]提出了一种基于TransUNet的机动微弱目标智能检测前跟踪算法,在无需依赖运动模型的情况下,实现多种运动状态下微弱目标的高效检测.但是该方法仅利用雷达数据实现了单传感器的智能TBD目标检测,不适用于多传感器系统,且应用背景仅限于空中目标,对于复杂的海面背景,该方法无法实现背景干扰的有效剔除,导致虚警率升高.利用多传感器多视角协同探测,能够充分利用信息融合优势,提高复杂环境下的目标检测性能^[16-18].但是针对海上机动微弱目标,如何利用多传感器多视角协同观测实现目标TBD检测、抑制背景干扰,目前仍鲜见公开文献报道.

针对上述挑战,本文提出面向海上微弱目标的雷达-红外多视角协同智能TBD技术.首先,对雷达回波数据进行低门限处理,以剔除部分能量较小的杂波和干扰,并减少后续计算量.接着,通过异构数据空间映射处理,将雷达量测点迹数据映射为红外像平面的虚拟像素点,形成单帧的雷达-红外融合图像,从而实现两传感器不同视角下量测数据的空间对准和信息整合,增强目标显著性,为后续处理奠定基础.在此基础上,采用最大值多帧累积处理获得多帧累积融合图像,以凸显运动微弱目标在图像序列中的空时相关性,并构

建基于雷达映射点与红外响应联合约束的目标潜在区域划定机制,提取可置信度较高的目标潜在区域,并剔除部分背景干扰.最后,根据目标的航迹形态与空时相关性特征提取需求,本文基于YOLOv11框架构建了自适应多尺度特征增强网络(Adaptive Multi-Scale Feature Enhancement YOLOv11, AMSFE-YOLOv11),以实现目标航迹检测与实例分割,并结合目标潜在区域对网络检测结果实施区域匹配与结果筛选,剔除不在候选区域内的误检框,进一步抑制干扰、降低虚警率.

本文的主要贡献如下:

(1)构建了一种用于多传感器TBD目标检测的技术框架,突破了传统TBD检测技术仅限于单一传感器的应用局限,并在该框架下实现了雷达-红外多视角数据融合,从而有效提升目标数据率,增强TBD能量积累效能,提高微弱目标检测性能.

(2)提出了基于雷达-红外异构数据同源性差异的背景干扰抑制技术,利用真实目标能在雷达和红外两个传感器中形成点迹,而部分背景干扰只能在单一传感器中形成点迹的差异(如海杂波通常仅在雷达回波中体现、海鸟和浮漂通常仅在红外图像中出现),通过雷达回波数据与红外图像进行比对分析,有效剔除背景干扰,显著降低虚警率.

(3)提出一种基于AMSFE-YOLOv11网络的机动微弱目标航迹智能检测技术,本方法突破了传统TBD依赖于先验运动模型假设的限制,能够在微弱目标发生机动的条件下,实现目标航迹特征和空时相关性的有效提取和能量累积,具有良好的鲁棒性和适用性.

(4)针对该技术开展了外场试验验证工作,在复杂海面环境下检验了所提方法对直线运动、机动转弯等微弱目标检测的有效性和优越性.相比单一传感器检测方法,本方法在保持更高检测概率的同时还大幅降低了虚警率,具有很好的工程应用前景.

2 雷达-红外多视角协同智能TBD总体处理架构

按照数据处理流程划分,海上微弱目标雷达-红外多视角协同智能TBD算法总体分为4个处理单元,具体包括低门限预处理单元、雷达-红外多视角虚拟融合图像生成单元、融合图像多帧累积与目标潜在区域划定单元、目标智能TBD检测单元,总体处理架构如图1所示.

首先,低门限预处理单元对雷达原始回波信号进行低门限检测处理,滤除幅值较低的背景干扰信号和噪声信号,以大幅降低后续处理计算量和虚警,同时尽可能保留目标回波信息.然后,将预处理后的雷达点迹数据输入雷达-红外多视角虚拟融合图像生成单元,结合雷达/红外观测姿态信息、红外相机内部参数信息,利




图1 雷达-红外多视角协同智能TBD总体处理架构

用雷达-红外异构数据空间映射模型,将雷达点迹映射到红外图像,形成虚拟红外点迹,得到像素级融合图像.此时融合图像中既包含红外图像原有信息,也包含雷达量测信息,不但实现这两类异构数据的量测空间统一,而且提高了目标量测数据率,有效增强目标量测空时相关特征.随后,在融合图像多帧累积与目标潜在区域划定单元中,引入最大值多帧累积机制,实现多个时刻融合图像的信息累积,进一步增强目标的空时相关特征.同时,利用真实目标在两种传感器中均产生响应的特性,构建基于雷达映射点与红外响应联合约束的目标潜在区域划定准则,在多帧累积图像中确定目标潜在区域,从而抑制潜在区域外的背景干扰.最后,在目标智能TBD检测单元,创新提出了AMSFE-YOLOv11网络,通过引入自适应特征增强(Adaptive Feature Enhancement Module, AFEM)模块、无参数显著性注意力(Simple parameter-free Attention Module, SimAM)模块和多膨胀通道细化器(Multi-Dilated Channel Refiner, MDCR)模块,显著提高网络的多尺度特征提取与小目标表征处理能力,以实现海上微弱目标轨迹的准确检测,并通过点迹回溯得到目标各个时刻的具体位置信息.

3 雷达数据低门限预处理

雷达回波数据中,存在大量幅值较低的背景干扰与噪声,如果直接对原始回波数据进行处理,不仅会增加计算量,还可能将噪声区域误判为目标区域,导致虚警率上升.针对该问题本文引入雷达低门限检测机制,对雷达回波数据进行预处理,首先对回波幅值进行归一化处理,将其映射至区间 $[0, 1]$,之后采用较低的幅值阈值对雷达回波数据进行低门限检测.具体处理过程如下:

设1帧雷达回波数据中的幅值范围为 $[Amp_{min}, Amp_{max}]$,对于任意的 $Amp \in [Amp_{min}, Amp_{max}]$,可通过式(1)进行归一化:

$$Amp' = \frac{Amp - Amp_{min}}{Amp_{max} - Amp_{min}} \in [0, 1] \quad (1)$$

在归一化的基础上,设定较低的阈值 τ_{radar} ,保留所有幅值大于 τ_{radar} 的量测点迹:

$$X = (d, \alpha) | Amp'(d, \alpha) > \tau_{radar} \quad (2)$$

其中, (d, α) 表示距离-方位量测点, X 为保留的雷达量测

点集合.在雷达P显内展示低门限预处理前后的点迹数据集,如图2所示.

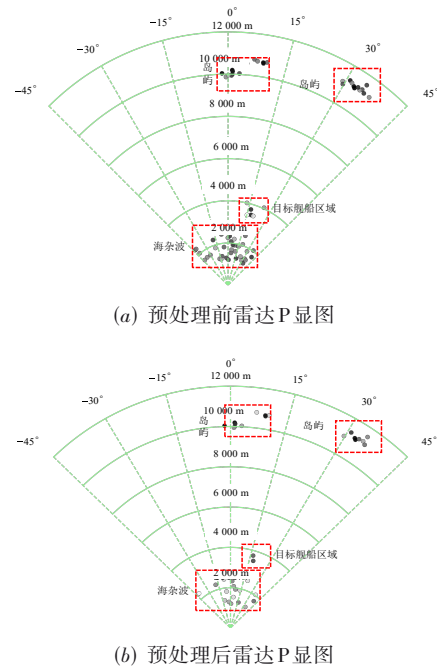


图2 低门限预处理前后的雷达点迹数据集

4 雷达-红外多视角虚拟融合图像生成

雷达与红外属于异构传感器,其获取信息的物理机理、工作频段、主被动工作方式均不相同,二者组合一方面能够获得目标不同维度的信息,为辨识目标、剔除干扰提供更为有力的数据支持;另一方面也带来了异构数据空间统一、信息整合的问题.

在海面复杂背景下,红外图像中常出现岛屿、海鸟、浮漂等与目标舰船灰度相近的干扰物,若单纯利用红外图像信息进行检测,这些背景干扰很容易与真实目标混淆,导致较高的虚警率,甚至造成态势误判.为提升对目标的辨识能力并有效剔除背景干扰,本文通过异构数据空间映射处理,将经过低门限预处理的雷达量测点迹映射为红外像平面的虚拟像素点,得到雷达-红外融合图像,这样一方面实现两类异构数据在红外像平面上的空间统一和信息整合,有效提高目标数据率,凸显目标点迹空时相关特征,改善目标检测性

能;另一方面,能够有效利用真实目标和背景干扰在雷达、红外传感器中的同源性差异,从而为后续目标潜在区域划定和背景干扰抑制提供前提条件.图3为雷达、红外传感器、海上目标空间位置关系示意图,雷达和红外传感器在不同位置从不同角度对海上目标进行协同探测.

由于雷达与红外传感器量测属性不同,其中雷达量测包含距离、方位角和幅度信息,红外传感器能够获得图像数据,其中包含灰度、方位与俯仰信息,且雷达、红外传感器量测均在各自局部坐标系内描述.我们的思路是通过雷达-红外异构数据空间映射模型构建与虚拟量测生成,将雷达点迹映射至红外图像中形成对应




图3 雷达、红外传感器、海上目标空间位置关系示意图

的虚拟像素点,以此实现雷达与红外传感器量测的空间统一与异构信息整合,图4为雷达量测映射至红外图像的原理示意图.




图4 雷达量测映射至红外图像的原理示意图

首先,根据雷达点迹量测的距离-方位信息,得到目标在WGS-84下的地理位置信息(经度、纬度、高度);然后,将红外传感器的地理坐标转换为地心地固坐标,并利用红外传感器外参矩阵将雷达点迹的地理坐标转换为红外传感器局部坐标;最后,通过红外传感器的内参矩阵将其局部坐标转换为红外图像中的像素坐标,结合归一化幅度信息生成雷达点迹在红外图像中的虚拟像素

点,从而得到雷达-红外像素级融合图像.详细描述如下.

设雷达对目标的量测为 $X_{t-r} = [d_t, \alpha_t]$, 其中, α_t 表示 t 时刻目标相对于雷达的方位角量测, d_t 表示 t 时刻目标的距离量测. 雷达的地理坐标为 $X_r = [\lambda_r, \phi_r, h_r]$, 其中, λ_r, ϕ_r, h_r 分别为雷达在地理坐标系中的经度、纬度和高度. 根据上述信息,结合 Vincenty 公式可以得到目标在不同时刻的纬度和经度^[19],如式(3)、式(4)所示:

$$\phi_t = \arctan \left[\frac{\sin(U_1) \cos(\sigma_t) + \cos(U_1) \sin(\sigma_t) \cos(\theta_t)}{(1-f_E) \sqrt{\sin^2(\delta_t) + (\sin(U_1) \sin(\sigma_t) - \cos(U_1) \cos(\sigma_t) \cos(\theta_t))^2}} \right] \quad (3)$$

$$\lambda_t = \lambda_r + \arctan \left(\frac{\sin(\sigma_t) \sin(\theta_t)}{\cos(U_1) \cos(\sigma_t) - \sin(U_1) \sin(\sigma_t) \cos(\theta_t)} \right) \quad (4)$$

其中, ϕ_t 和 λ_t 分别表示目标在不同时刻下的纬度和经度, U_1 为归化纬度,使公式能够有效地适用于椭球体:

$$U_1 = \arctan \left[(1-f_E) \tan(\phi_r) \right] \quad (5)$$

其中, f_E 为 WGS-84 坐标下的地球扁率.

设 σ_t 为雷达与目标间的角距离,则有:

$$\sigma_t = \frac{\sqrt{d_t^2 - (h_r - h)^2}}{b \cdot A} \quad (6)$$

其中, h 为目标在地理坐标系下的高度,本文中目标位于海面,即 $h=0$,而 $\sqrt{d_t^2 - (h_r - h)^2}$ 为雷达与目标间的

水平距离, $b=6356752$ m 代表地球的短半轴, A 是一个与扁率和纬度相关的缩放因子,起到校正弧长的作用,即

$$A = 1 + \frac{u_1^2}{16384} (4096 + u_1^2(-768 + u_1^2(320 - 175u_1^2))) \quad (7)$$

其中, u_1^2 是与归化纬度 U_1 有关的参数:

$$u_1^2 = \cos^2 U_1 \frac{a^2 - b^2}{b^2} \quad (8)$$

其中, $a=6378137$ m 代表地球长半轴.

可得目标的实际方位角 θ_t :

$$\theta_t = \alpha_t + \theta_r \quad (9)$$

其中, θ_r 为雷达天线指向相对于正北方向的夹角.

δ_t 为目标实际方位角在归化纬度平面中的角度修正量,如式(10)所示:

$$\delta_t = \arcsin \left[\cos(U_1) \sin(\theta_t) \right] \quad (10)$$

将目标在相机坐标系中的坐标 \mathbf{P}_{cam} 转换为红外图像中的像素坐标 (p_{tx}, p_{ty}) :

$$\begin{bmatrix} p_{tx} \\ p_{ty} \\ 1 \end{bmatrix} = \mathbf{K} \mathbf{P}_{\text{cam}} \quad (11)$$

上式中, \mathbf{K} 为相机的内参矩阵:

$$\mathbf{R} = \begin{bmatrix} \cos(\text{yaw})\cos(\text{pitch}) & \cos(\text{yaw})\sin(\text{pitch})\sin(\text{roll}) - \sin(\text{yaw})\cos(\text{roll}) & \cos(\text{yaw})\sin(\text{pitch})\cos(\text{roll}) + \sin(\text{yaw})\sin(\text{roll}) \\ \sin(\text{yaw})\cos(\text{pitch}) & \sin(\text{yaw})\sin(\text{pitch})\sin(\text{roll}) + \cos(\text{yaw})\cos(\text{roll}) & \sin(\text{yaw})\sin(\text{pitch})\cos(\text{roll}) - \cos(\text{yaw})\sin(\text{roll}) \\ -\sin(\text{pitch}) & \cos(\text{pitch})\sin(\text{roll}) & \cos(\text{pitch})\cos(\text{roll}) \end{bmatrix} \quad (14)$$

其中, f 为相机焦距, (c_x, c_y) 为图像中心坐标, \mathbf{R} 为相机旋转矩阵, roll 表示相机的水平角度, pitch 表示相机相对于地面的俯仰角度, yaw 表示相机的朝向, 正北为 0° , 顺时针为正, N 为目标点所在纬度的卯酉圈半径, e^2 为椭圆偏心率平方, (X_c, Y_c, Z_c) 为红外相机的地心地固坐标:

$$N = \frac{a}{\sqrt{1 - e^2 \sin^2(\phi_t)}} \quad (15)$$

$$e^2 = \frac{a^2 - b^2}{a^2} \quad (16)$$

根据雷达点迹映射到红外图像的像素坐标 (p_{tx}, p_{ty}) , 以及雷达点迹的归一化幅度信息, 就可以构建雷达到红外图像的虚拟像素点, 从而得到这两类异构传感器像素级融合图像.


通过上述方法, 即可将雷达量测值映射至红外图像上, 得到单帧像素级融合图像, 实测数据处理过程如图 5 所示. 如图 5(a) 所示, 雷达 P 显图展示了经低门限预处理后的海面背景雷达回波点迹分布情况, 图中散布的亮点包含目标小艇回波、岛屿强散射回波以及海杂波. 图 5(b) 为单帧红外图像, 清晰呈现了海面场景热辐射特征, 包括两艘目标小艇、岛屿及海鸟等. 图 5(c) 展示了雷达量测投影至红外图像平面后生成的雷达-红外虚拟融合图像, 红色像素点表示雷达到红外的映射点分布. 通过对比可见, 真实目标在雷达和红外两种传感器中均形成有效响应, 而海鸟仅在红外图像中可见, 海杂波仅在雷达回波中出现, 这种差异性为后续的目标潜在区域划定和背景干扰抑制提供了基础依据.

5 融合图像多帧累积与目标潜在区域划定


由于海上微弱目标雷达回波能量较小, 且通常在红外图像中所占像素数量较少、特征不显著, 复杂海面背景下极易受到杂波或干扰物的影响, 难以实现稳定检测, 且容易产生较多虚警. 针对上述问题, 我们基于 TBD 思想利用雷达-红外融合图像提高目标点迹数据

$$\mathbf{K} = \begin{bmatrix} f & 0 & c_x \\ 0 & f & c_y \\ 0 & 0 & 1 \end{bmatrix} \quad (12)$$


$$\mathbf{P}_{\text{cam}} = \mathbf{R} \begin{bmatrix} (N+h)\cos(\phi_t)\cos(\lambda_t) \\ (N+h)\cos(\phi_t)\sin(\lambda_t) \\ [N(1-e^2)+h]\sin(\phi_t) \end{bmatrix} - \mathbf{R} \begin{bmatrix} X_c \\ Y_c \\ Z_c \end{bmatrix} \quad (13)$$



(a) 雷达 P 显图



(b) 红外单帧图像



(c) 雷达-红外虚拟融合图像

图 5 雷达-红外像素级融合实测数据处理过程

率, 并通过最大值多帧累积进一步凸显目标点迹时空相关特征, 为下一步目标检测创造更有利条件. 同时, 基于目标量测雷达-红外同源的本质特征, 提出一种目标潜在区域划定方法, 以有效抑制背景干扰, 降低虚警率. 具体流程如图 6 所示.

为增强运动微弱目标的时空相关性并提升其在复杂背景下的可分性, 本文基于雷达-红外空间对准后的

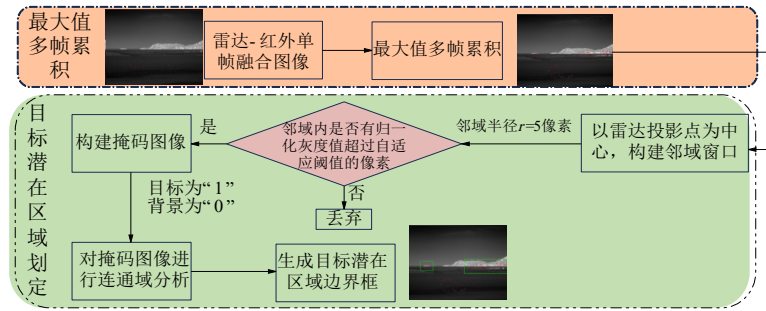


图6 多帧累积与目标潜在区域划定流程图

单帧融合图像序列,构建了最大值多帧累积策略.该方法以雷达-红外单帧融合图像作为输入,对连续10帧序列中同一空间位置的像素值进行逐点比较,并保留其中的最大值以构建累积图像.


我团队在青岛灵山岛海域开展外场试验并采集了大量实测数据,图7为经处理后得到的部分单帧融合图像与10帧累积融合图像.

在完成最大值多帧累积后,为进一步从图像中提取可能存在目标的区域,本文构建了一种基于雷达投影点与红外图像联合约束的目标潜在区域划定方法.在目标潜在区域的构建过程中,本文充分利用了目标雷达量测投影点与红外图像数据的同源性,以实现背景干扰与目标区域的有效区分.其具体依据是真实舰船目标在图像上应同时具备稳定的雷达投影点和红外响应,而仅具有单一模态特征的干扰将被剔除.具体而言,海鸟虽然在图像中通常表现为亮斑,具有一定的热辐射特征,但通常无法形成雷达回波,其在初始阶段即因缺乏雷达量测信息而被排除.海杂波能够在雷达中产生量测点迹,从而被短暂纳入候选区域.然而,由于海水表面温度分布较为均匀,缺乏明显的红外辐射响应,其在图像中的灰度不足以满足判定条件,因此最终被识别为背景区域.与此相对,真实舰船目标和岛屿区域同时具备稳定的雷达散射特性和显著的红外辐射特性,在两类传感器中均产生有效响应.这种双重特征使其能够在融合判别过程中被保留为潜在目标区域.通过该判别机制,仅具单一模态特征的干扰被有效抑制,而具备双模态特性的舰船目标区域得以凸显.具体方法如下.


设10帧累积后的融合图像为 I_{fusion} , 雷达投影点集为 $P_r = \{p_i^r = (x_i^r, y_i^r) | i = 1, 2, \dots, N_r\}$, 对于每个雷达投影点 p_i^r , 首先构建以该点为中心的圆形邻域窗口 Ω_i :

$$\Omega_i = \left\{ (x, y) \mid \sqrt{(x - x_i^r)^2 + (y - y_i^r)^2} \leq r \right\} \quad (17)$$


其中, $r = 5$ 像素的选择基于目标在图像中的尺寸. 该邻域既能覆盖小型船只目标的主体区域, 又避免范围过大引入背景干扰. 在此邻域内, 提取所有红外像素的灰




(a) 单帧融合图像 1



(b) 单帧融合图像 2



(c) 单帧融合图像 3



(d) 10帧最大值累积融合图像

图7 单帧融合图像与10帧累积融合图像

度值集合:

$$I_{\Omega_i} = \{I_{\text{fusion}}(x, y) | (x, y) \in \Omega_i\} \quad (18)$$

为消除不同区域间的亮度差异影响,对红外图像灰度进行全局归一化处理:

$$\bar{I}_{\Omega_i}(x, y) = \frac{I_{\Omega_i}(x, y) - I_{\min}}{I_{\max} - I_{\min}} \quad (19)$$

其中, I_{\min} 和 I_{\max} 分别为整幅图像的最小和最大灰度值.

目标潜在区域的二值掩码图像构造准则如下:为实现对灰度特征的自适应分割,本文采用大津法(Otsu's method)^[20]自动确定阈值 τ_{target} . 该方法通过最大化类间方差来寻找最佳分割点从而确定阈值. 当归一化灰度值超过阈值 τ_{target} 时,判定该位置可能存在有效目标响应,形成初始候选点集. 随后构建二值掩码图像,其中目标潜在区域标记为 1,背景区域标记为 0.

$$\begin{aligned} \text{TargetFlag}_i &= 1, \\ \text{if } \max(x, y) \in \Omega_i \text{ and } \bar{I}_{\Omega_i}(x, y) > \tau_{\text{target}} & \\ \text{else TargetFlag}_i &= 0 \end{aligned} \quad (20)$$

得到掩码图像后,通过八连通域分析算法对掩码图进行处理,合并空间邻接的响应区域. 最终采用最小外接矩形算法提取各连通域的几何边界,生成目标潜在区域,如图 8 所示.

6 基于 AMSFE-YOLOv11 网络的智能 TBD 检测算法

融合图像中微弱目标尺寸通常仅占数个像素,且在复杂海面背景中通常呈现低对比度特征,极易在神经网络的特征提取与下采样过程中被淹没或误判. 针对上述问题,本文在 YOLOv11 网络^[21,22]框架的基础上引入了三类模块:首先,引入了 AFEM 模块,以提升目标




图 8 目标潜在区域

与背景的区分度;然后,针对融合图像通道表达中目标对比度不足、边界模糊的问题,引入了 SimAM 模块;最后,针对微弱目标特性引入 MDCR 模块. 该模块通过引入不同膨胀率的卷积实现多尺度特征建模,在提取过程中既能突出机动目标在多帧累积图像中呈现的规律性航迹特征,又能有效抑制不规则杂波点的干扰. 三者协同作用,有效缓解了微弱目标在特征提取过程中的信息丢失与漏检误检问题,提升了海面背景下微弱机动目标检测精度与鲁棒性.

6.1 AMSFE-YOLOv11 检测网络构建

AMSFE-YOLOv11 目标检测网络框架如图 9 所示,其基本结构由三大部分构成:Backbone(主干网络)、Neck(多尺度特征融合层)与 Head(检测头). 在此基础上,将 SimAM 模块和 AFEM 模块嵌入至 Backbone 和 Neck 中,将 MDCR 模块集成至 Head 阶段,从而实现了对空间位置信息与微弱目标语义表达的双重增强,更加有利于微弱机动目标多时刻量测空时相关性的提取.

表 1 为 AMSFE-YOLOv11 网络的主要模块功能表,用于表示各个模块的输入特征、输出特征以及在网络中的作用.

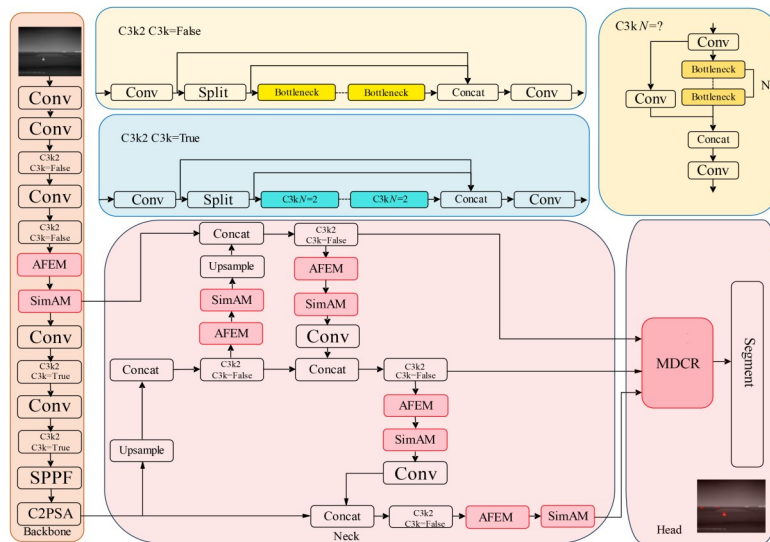


图 9 AMSFE-YOLOv11 检测网络框架图

表1 AMSFE-YOLOv11 网络主要模块功能

| 模块名称 | 输入特征 | 输出特征 | 作用 |
|---------------|-------------------|-----------|------------------------------|
| Conv 初始卷积层 | 原始图像 | 基础特征图 | 构建低层视觉特征,为后续特征提取奠定基础 |
| C3k2/C3k 残差块 | Conv 输出特征 | 深层语义特征 | 通过跨层连接增强特征表达稳定性与鲁棒性 |
| AFEM 模块 | C3k2/C3k 输出 | 加权特征图 | 联合建模空间与通道注意力,突出目标显著区域、抑制背景干扰 |
| SimAM 模块 | AFEM 输出 | 显著性增强特征 | 基于能量函数分配显著性权重,强化微弱目标边缘特征 |
| SPPF 空间金字塔池化层 | 经过 SimAM 增强后的深层特征 | 多尺度上下文特征 | 聚合不同尺度的上下文信息,扩展感受野、丰富语义特征 |
| C2PSA 模块 | SPPF 输出 | 深层特征 | 通过交叉阶段空间注意力强化空间相关性与特征传递 |
| Upsample 模块 | C2PSA 输出 | 上采样特征图 | 提升特征分辨率,便于多尺度特征融合 |
| Concat 模块 | 上采样特征与浅层特征 | 融合特征图 | 跨层拼接不同尺度特征,增强语义与细节交互 |
| MDCR 模块 | 不同尺度的融合特征 | 多维多尺度强化特征 | 采用多膨胀卷积实现多维多尺度特征建模,提取时空连续信息 |
| Segment 模块 | MDCR 输出 | 实例分割结果 | 综合多维多尺度特征完成实例分割 |

AMSFE-YOLOv11 的主干网络主要用于提取图像中的层级特征,包括空间结构、边缘轮廓及基础纹理等。在本文的融合图像中,目标通常呈现对比度低、边界模糊、背景干扰强等特点,若主干网络缺乏对全局与局部显著性特征的建模能力,尤其在低对比度红外图像中,极易导致舰船目标的边缘与细节被背景噪声淹没,从而造成目标区域特征响应弱化。为解决这一问题,本文在主干网络和多尺度特征融合层中引入了 AFEM 模块与 SimAM 模块。其中,AFEM 模块通过空间与通道维度的联合建模,自适应调节特征分布,从全局层面突出目标相关区域并抑制背景干扰;SimAM 模块基于能量函数,对特征图的每一个像素位置进行显著性评分与自适应加权,从而逐像素抑制噪声、增强细长结构与边缘响应,以更好地提取多时刻点迹构成的狭长状连贯航迹,更有利于目标检测。二者的级联作用不仅在特征提取早期有效提升了对微弱目标空间结构的敏感性与边界保真度,同时也为后续检测与分割任务提供了更加清晰且抗干扰的语义特征表示。下面分别针对 AFEM 与 SimAM 两个模块的内在机理进行分析。

AFEM 模块由空间注意力与通道注意力两个子结构组成,能够在特征图中动态突出对目标识别有价值的区域与通道信息^[23]。具体地,空间注意力子模块用于捕捉图像中显著区域的空间依赖关系,而通道注意力模块则提升了网络对语义关键通道的敏感度,从而在目标特征较弱或被背景干扰掩盖时,有效提升目标的可分性与显著性。

空间注意力机制中,首先对输入的特征图 $F \in T^{C \times H \times W}$ 进行通道维最大池化和平均池化:

$$F_{\max}^s = \max_{i=1}^C F_i \in T^{1 \times H \times W} \quad (21)$$

$$F_{\text{avg}}^s = \frac{1}{C} \sum_{i=1}^C F_i \in T^{1 \times H \times W} \quad (22)$$

其中, T, C, H, W, F_{\max}^s 分别为张量空间、通道数、高度、

宽度以及在通道维上进行最大池化后的结果, F_{avg}^s 表示在通道维上进行平均池化后的结果。

然后,将两张池化图在通道维拼接后输入一个卷积层,经过激活函数后得到空间注意力图:

$$M_s = \text{Sig} \left(\text{Conv}_{7 \times 7} \left([F_{\text{avg}}^s; F_{\max}^s] \right) \right) \quad (23)$$

其中, Conv 表示卷积操作; $[\cdot; \cdot]$ 表示拼接操作; Sig 为 Sigmoid 激活函数,目的是将输出值归一化到 $[0, 1]$; $M_s \in T^{1 \times H \times W}$ 为空间注意力图。该模块能有效提取图像中可能存在目标的空间响应区域,有助于提升对微弱目标的检测能力。

通道注意力机制中,首先对 M_s 做全局平均池化(Global Average Pooling, GAP)和全局最大池化(Global Max Pooling, GMP):

$$f_{\text{avg}} = \text{GAP}(M_s) \in T^{C \times 1 \times 1} \quad (24)$$

$$f_{\text{max}} = \text{GMP}(M_s) \in T^{C \times 1 \times 1} \quad (25)$$

池化后的结果经过共享多层感知机 (MuLtilayer Perceptron, MLP) 建模后加权,并通过 Sigmoid 激活函数得到通道注意力图 M_c 。

$$M_c = \text{Sig} \left[\text{MLP}(f_{\text{avg}}) + \text{MLP}(f_{\text{max}}) \right] \quad (26)$$

基于神经科学理论 SimAM 模块能够通过能量函数评估每个神经元的重要性^[24],该模块认为信息丰富的神经元会抑制周围神经元,表现出与其他神经元不同的激活模式。通过计算能量函数,其能够自适应地产生像素级注意力权重,在不依赖卷积方向编码的情况下,有效增强边缘模糊区域的显著性响应,并抑制背景噪声,使检测网络在保持轻量化的同时具备更强的位置感知能力和形态敏感性,从而提高对微弱目标的特征提取能力。

给定输入特征图 $F \in T^{C \times H \times W}$, SimAM 对每个像素 (i, j) 在每个通道内计算能量值 E_{ij} :

$$E_{i,j} = \frac{4(\sigma^2 + \beta_{\text{SimAM}})}{(F_{i,j} - \mu)^2 + 2(\sigma^2 + \beta_{\text{SimAM}})} \quad (27)$$

其中, $F_{i,j}$ 表示像素值; μ 表示该通道内所有像素的均值; σ^2 表示该通道内所有像素的方差; β_{SimAM} 为稳定因子, 防止分母为 0. 该能量函数衡量了像素与通道整体分布的差异程度, 差异越大, 能量值越小, 然后将能量值 $E_{i,j}$ 转换为权重系数:

$$\omega_{i,j} = \frac{1}{1 + E_{i,j}} \quad (28)$$

能量值越小, 权重越高, 从而能保留更多的显著特征, 得到最终输出的特征图为

$$Y_{i,j} = \omega_{i,j} F_{i,j} \quad (29)$$

这样, SimAM 就通过评估每个像素相对于通道整体分布的偏离程度, 赋予异常响应区域更高的权重. 这种基于统计差异的显著性建模方式, 使得网络能够自适应地强化目标边缘的表达, 同时抑制均匀海面背景的冗余响应, 从而在不增加计算参数的前提下显著提升了海上微弱目标的检测能力.

AMSFE-YOLOv11 网络的检测头是目标检测的关键决策区域, 主要负责融合多尺度语义特征并进行目标分类与边界框回归. 在该阶段, 微弱目标检测的困难主要表现为特征响应易被高层语义“稀释”、尺度过小导致信息表达不充分. 为此, 本文在检测头中引入 MDCR 模块, 利用并行设置的不同扩张率膨胀卷积构建多感受野路径, 增强网络对不同空间尺度信息的融合能力. 同时, 通过通道注意力机制细化微弱目标相关特征通道, 有效抑制冗余背景干扰信息, 从而具备更强的微弱目标响应强化能力, 能够显著提升微弱目标在高层特征图中的检测敏感性和准确性.

在本文的 10 帧累积图像中, 微弱目标往往表现为沿时间维度逐渐延展的轨迹, 而虚警与杂波则更倾向于呈现不规则、孤立的点状分布. 由于微弱目标在下采样过程中易受干扰, 其弱小特征往往被掩盖甚至淹没. 针对这一问题, MDCR 模块通过多尺度膨胀卷积的设计, 在特征提取时同时兼顾局部细节和全局上下文^[25]: 一方面, 较小的膨胀率卷积能够聚焦于细粒度的空间纹理, 从而保证微弱目标在局部区域内的完整表征; 另一方面, 较大的膨胀率卷积则扩展了感受野, 能够捕捉目标在更大范围内的平滑演化趋势, 突出其在时序上的连续性.

通过这种多尺度信息的并行建模与跨通道融合, MDCR 模块在特征图中形成了“稳健的表征”: 对于在 10 帧累积后形成连续轨迹的微弱目标, 其特征在不同膨胀尺度下均能保持一致, 从而在跨通道融合时得到强化; 而对于杂波和虚警, 由于其缺乏跨尺度和跨帧的一致性, 往往在跨通道融合过程中被抵消或弱化. 最

终, MDCR 模块能够在特征层面凸显目标的空时相关性, 将其在多帧中逐渐演化的规律航迹提取出来, 为后续目标航迹检测提供坚实基础. MDCR 模块的具体作用机理如下.

MDCR 模块首先将输入特征图 $F \in T^{C \times H \times W}$ 沿通道维度均匀划分为 4 个子分支:

$$F_n = F \left[n \frac{C}{4} : (n+1) \frac{C}{4} \right], n \in \{0, 1, 2, 3\} \quad (30)$$

其中, $F_n \in T^{\frac{C}{4} \times H \times W}$ 表示第 n 个子分支, 然后对每个子分支应用不同扩张率的深度可分离卷积:

$$Z_n = \text{Conv}_{\text{dw}}(F_n; \text{ep}_n) \quad (31)$$

其中, $\text{ep}_n \in \{1, 2, 4, 8\}$ 为第 n 个分支的扩张率.

卷积提取后, MDCR 模块并不直接拼接每个分支的输出, 而是对每一个“同位置通道”进行重新组合, 即将来自不同感受野的对应通道融合在一起, 从而将不同尺度的信息在每个通道层面进行交叉建模, 有助于提升通道间协同建模的表达能力. 将融合后的特征重新组合成完整的特征图后, 使用一个轻量级的卷积操作进行整合, 接着施加归一化与激活函数, 使得特征图在语义层面更加清晰, 突出关键信息, 抑制冗余通道响应.

与传统基于物理模型或先验假设的目标检测方法不同, AMSFE-YOLOv11 采用数据驱动的端到端学习范式, 无需依赖复杂的目标机动模型. 具体而言, AFEM 模块通过空间与通道维度的联合建模, 能够自适应地从数据中学习目标与背景的区分性特征, 而非依赖预设的目标特征模板; SimAM 模块基于能量函数自动评估每个像素的显著性, 无需人工定义何为“显著”, 而是让网络从大量样本中自主学习目标的显著性模式; MDCR 模块通过多尺度膨胀卷积自动捕捉目标在多帧累积图像中的规律性航迹特征, 无需预先建立目标机动轨迹的数学模型. 这种数据驱动的检测机制使得网络能够自适应地应对不同类型的机动目标, 以及复杂多变的干扰环境, 具有更强的泛化能力和鲁棒性.

总结上述分析, AMSFE-YOLOv11 网络的具体计算流程如下.

6.2 基于微弱目标航迹特征的损失函数构建

传统的边界框回归损失函数在处理小尺度目标时极易出现梯度消失问题, 严重制约网络的收敛性能. 针对本文融合图像中目标航迹呈现的细长形态特征, 本文提出了一种细长目标专用损失函数 (Elongated Small Target Loss, EST Loss), 从概率分布建模、形状约束和边界优化三个维度构建综合优化目标, 如算法 1 所示.

EST 损失函数的总体形式定义为

$$L_{\text{EST}} = L_{\text{wasserstein}} + \beta_1 L_{\text{shape}} + \beta_2 L_{\text{boundary}} \quad (32)$$

其中, $L_{\text{wasserstein}}$ 为改进的 Wasserstein 距离损失项^[26],

算法1 AMSFE-YOLOv11 网络流程

Backbone 特征提取

步骤1: 初始特征提取(P1-P2)

1. 输入图像→Conv(64)→P1 特征图

2. P1→Conv(128)→P2 特征图

3. 完成2级下采样,提取低级视觉特征

步骤2: 中层特征增强(P3-P4)

4. P2→C3k2→P3 特征图

5. P3→C3k2 + AFEM→P4 特征图

6. 通过残差连接保持微弱目标细节,AFEM自适应增强显著特征

步骤3: 深层特征建模(P5)

7. P4→C3k2→SimAM→P5 特征图

8. SimAM增强低对比度目标的空间细节表达

步骤4: 全局上下文聚合

9. P5→C3k2(高通道)→SPPF→P5_{global}

10. 多尺度池化扩大感受野

Neck 特征融合

步骤5: 自顶向下路径

11. P5_{global}→Upsample→Concat(P4)→C3k2→AFEM→SimAM→F4

12. F4→Upsample→Concat(P3)→C3k2→AFEM→SimAM→F3

步骤6: 自底向上路径

13. F3→Conv→Concat(F4)→C3k2→AFEM→SimAM→F4_{final}

14. F4_{final}→Conv→Concat(P5_{global})→C3k2→AFEM→SimAM→F5_{final}

步骤7: 多尺度特征输出

15. 输出 F3_{final}(8倍下采样)、F4_{final}(16倍下采样)、F5_{final}(32倍下采样)

Head 检测输出

步骤8: 多尺度特征拼接

16. [F3_{final}, F4_{final}, F5_{final}]→Concatenate→Features_{concat}

17. 三个尺度特征图沿通道维度拼接

步骤9: MDCR 多扩张率卷积处理

18. Features_{concat}→DilatedConv(rate=1)→Branch1

19. Features_{concat}→DilatedConv(rate=2)→Branch2

20. Features_{concat}→DilatedConv(rate=4)→Branch3

21. Features_{concat}→DilatedConv(rate=8)→Branch4

22. [Branch1, Branch2, Branch3, Branch4]→Concatenate→ChannelAttention→MDCR_{features}

步骤10: 统一检测输出

23. MDCR_{features}→Conv_{BBox}→掩膜分割预测

24. 输出实例分割结果

L_{shape} 为形状感知损失项, L_{boundary} 为边界清晰度损失项, β_1 和 β_2 为平衡各损失项贡献的超参数. 超参数 β_1 和 β_2 在损失函数中分别用于平衡形态感知损失与边界清晰度损失的相对贡献,其核心作用是协调模型在几何结构学习与边界精细化之间的关注比例. 其中, β_1 控制网络对目标几何一致性的关注程度,使模型在训练过程中能够更好地约束检测框的长宽比与延展方向,确保航迹结构完整、形态稳定; β_2 调节网络对边界细节的关

注强度,促使模型在检测框边缘区域形成更高的响应对比,从而提升目标轮廓的定位精度. 模型在前期以几何约束为核心快速收敛,掌握航迹的整体结构特征;在后期则由边界项引导细化检测结果,使边缘更清晰、误检更少.

考虑到10帧融合图像中目标航迹的细长特性,本文采用各向异性高斯分布对边界框进行建模. 对于预测框和真实框,分别构建高斯分布 $N(\mathbf{v}_p, \boldsymbol{\Sigma}_p)$ 和 $N(\mathbf{v}_g, \boldsymbol{\Sigma}_g)$, 其2-Wasserstein距离定义为

$$L_{\text{wasserstein}} = \sqrt{\|\mathbf{v}_p - \mathbf{v}_g\|^2 + \text{Tr}\left(\boldsymbol{\Sigma}_p + \boldsymbol{\Sigma}_g - 2\left(\boldsymbol{\Sigma}_p^{\frac{1}{2}} \boldsymbol{\Sigma}_g \boldsymbol{\Sigma}_p^{\frac{1}{2}}\right)^{\frac{1}{2}}\right)} \quad (33)$$

其中, \mathbf{v} 表示边界框中心坐标, $\text{Tr}(\cdot)$ 表示矩阵的迹算子. 为精确刻画细长目标航迹的空间分布特性,协方差矩阵采用对角结构:

$$\boldsymbol{\Sigma} = \begin{pmatrix} \psi_\ell^2 & 0 \\ 0 & \psi_s^2 \end{pmatrix} \quad (34)$$

其中, $\psi_\ell = \max(W, H)/2$ 表示沿目标主轴方向的分布参数, $\psi_s = 1.5$ 为固定的短轴分布参数,对应于目标典型宽度约3个像素的先验知识. 这种非对称设计能够更精确地表征细长目标航迹的空间不确定性分布.

为强化网络对细长形态的学习能力并抑制过宽的误检框,引入形态感知损失函数:

$$L_{\text{shape}} = e^{-\gamma A_{\text{box}}} \left(\left| \frac{h_p}{w_p} - \frac{h_g}{w_g} \right| + \lambda_{\text{loss}} \max(0, w_p - \tau_{\text{loss}}) \right) \quad (35)$$

其中, h 和 w 分别表示边界框的长度和宽度, A_{box} 为边界框面积. 指数权重因子 $e^{-\gamma A_{\text{box}}}$ 确保微弱目标获得更高的优化优先级, γ 为衰减系数. 第一项约束预测框与真实框的长宽比一致性,第二项通过软阈值函数惩罚宽度超过 τ_{loss} 像素的预测框, λ_{loss} 为宽度惩罚系数.

针对图像中目标边界模糊的特点,设计边界清晰度损失以增强边界定位精度:

$$L_{\text{boundary}} = \frac{1}{|\text{Bou}|} \sum_{(x,y) \in \text{Bou}} \left(1 - \exp\left(-\frac{(I_p(x,y) - I_{\text{bg}})^2}{2\sigma_{\text{edge}}^2}\right) \right) \quad (36)$$

其中, Bou 表示预测框边界上的像素集合, $|\text{Bou}|$ 为边界像素总数, $I_p(x,y)$ 为边界像素 (x,y) 处的图像强度值, I_{bg} 为局部背景强度均值, σ_{edge} 控制边界锐度的敏感程度. 该损失函数通过高斯核函数度量边界像素与背景的对比度,当边界处于高对比度区域时损失值较小,从而引导网络学习更准确的边界定位.

上述三个损失项协同作用: Wasserstein距离损失提供稳定的梯度信号,形状感知损失约束目标的几何

特性,边界清晰度损失优化边界定位精度,共同构成了适用于细长目标航迹检测的综合优化.

6.3 点迹回溯

在得到目标锚框以及实例分割结果后,由于检测框往往覆盖的是目标在多个时间帧内的累积响应区域,通常呈现为一条细长的“线段”或连通区域.然而在实际观测中,目标往往只对应若干离散的雷达投影点或局部高亮像素.为此,引入点迹回溯机制,以实现从区域级检测结果向离散像素级观测结果的恢复与重构.

该方法首先依据分割区域在图像平面中确定目标范围,并在该范围内逐一提取像素点集合.同时,从雷

达观测数据中筛选出落入该范围的投影点,最终得到目标的离散点迹:

$$\text{Track} = Q \cup P_{\text{radar}} \quad (37)$$

其中, Q 表示分割区域内提取的像素点集合, P_{radar} 表示落入该区域的雷达投影点集合, Track 为回溯得到的落入该分割区域的全部像素点和雷达投影点集合.

7 总体算法流程

图 10 为本文总体算法流程框图,展示了所提的海上微弱目标雷达-红外多视角协同智能TBD算法的详细流程.

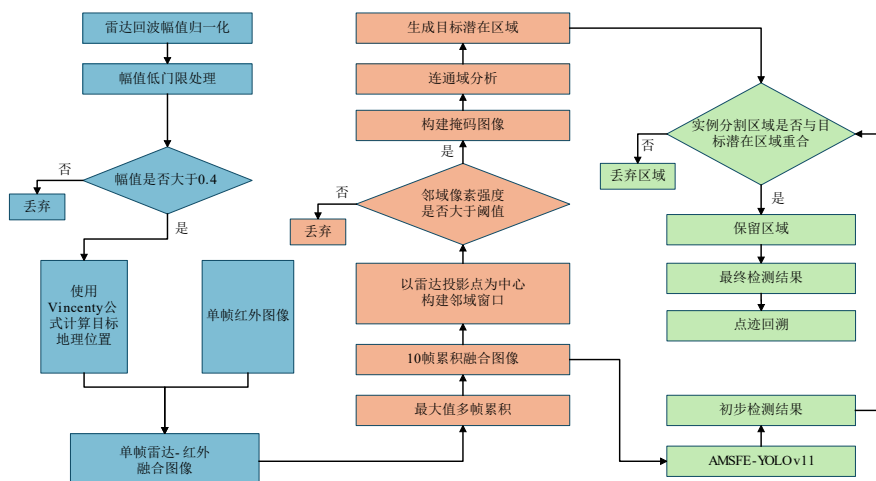


图 10 算法流程框图

算法伪代码如算法 2 所示.

算法 2 海上微弱目标雷达-红外多视角协同智能TBD算法

输入:

- (d, α, Amp) // 雷达量测,距离、方位、幅值
- $(\lambda_r, \varphi_r, h_r)$ // 雷达地理坐标(WGS-84)
- $(\lambda_c, \varphi_c, h_c)$ // 红外相机地理坐标(WGS-84)
- K // 相机内参矩阵
- R // 相机旋转矩阵

输出:

- DetMasks // 最终实例分割结果
- Track_n // 点迹回溯结果

1. 低门限预处理
2. FOR $k = 1, 2, \dots, M$ do
3. FOR each Amp in 所有雷达量测 do
4. $\text{Amp}' \leftarrow (\text{Amp} - \text{Amp}_{\min}) / (\text{Amp}_{\max} - \text{Amp}_{\min})$
5. IF $\text{Amp}' < \tau_{\text{radar}}$ then 丢弃该量测
ELSE 进入预处理后雷达量测
6. end FOR
7. RETURN P_k
8. 雷达-红外像素级融合
9. // 雷达极坐标 \rightarrow WGS-84(Vincenty)
10. FOR $k = 1, 2, \dots, M$, FOR each P_k do

11. $(\lambda_t, \varphi_t, h) \leftarrow \text{Vincenty}(d, \alpha; \lambda_r, \varphi_r, h_r)$
//海上目标 $h=0$
12. RETURN $(\lambda_t, \varphi_t, h)$
13. // WGS-84 \rightarrow ECEF \rightarrow 相机坐标 \rightarrow 图像平面
14. $X_c^{\text{ecef}} \leftarrow \text{Geo2ECEF}(\lambda_c, \varphi_c, h_c)$
//红外相机坐标转换
15. FOR each $(\lambda_t, \varphi_t, h)$ do
16. $X_t^{\text{ecef}} \leftarrow \text{Geo2ECEF}(\lambda_t, \varphi_t, h)$
//雷达量测值坐标转换
17. $P_{\text{cam}} \leftarrow R \cdot X_t^{\text{ecef}} - R \cdot X_c^{\text{ecef}}$
//雷达量测值 \rightarrow 相机坐标
18. $(u, v, 1)^T = K \cdot P_{\text{cam}}$ //相机坐标 \rightarrow 图像平面
19. RETURN $I_{\text{fusion}}^k(x, y)$
//得到单帧雷达-红外融合图像
20. 多帧累积与目标潜在区域划定
21. FOR $k = 1, 2, \dots, M$ do
22. $I_{\text{acc}}(x, y) \leftarrow \max_k \{I_{\text{fusion}}^k(x, y)\}$
23. RETURN $I_{\text{acc}}(x, y)$
24. $P \leftarrow \bigcup_{k=1, 2, \dots, M} \{P_k\}$
25. 初始化二值掩码 $M_{\text{mask}}(x, y) \leftarrow 0$
26. FOR each $p_i \in P$ do

```

27. 定义圆形邻域

$$\Omega_i = \{(x, y) | (x - x_i)^2 + (y - y_i)^2 \leq r^2\}$$

28. 取  $I_{\Omega_i} \leftarrow \{I_{\text{acc}}(x, y) | (x, y) \in \Omega_i\}$ 
29. # 归一化
30.  $\bar{I}_{\Omega_i}(x, y) \leftarrow (I(x, y) - I_{\min}) / (I_{\max} - I_{\min})$ 
31. # 计算阈值
32.  $\tau_{\text{target}} = \text{Otsu}(\bar{I}_{\Omega_i}(x, y))$ 
33. # 判别设置掩码
34. IF  $\bar{I}_{\Omega_i}(x, y) > \tau_{\text{target}}$  THEN
35. 将  $\Omega_i$  内所有像素置 1:

$$M_{\text{mask}}(x, y) \leftarrow 1$$

36. end IF
37. end FOR
38. 通过连通域合并与最小外接矩形得到潜在区域集合  $B$ 
39. 目标智能 TBD 检测
40.  $\text{Det}0 \leftarrow \text{AMSFE-YOLOv11}(I_{\text{acc}})$ 
//实例分割
41.  $\text{DetMasks} \leftarrow \{S \in \text{Det}0 | \text{IoU}(S, B) > 0\}$ 
//结合目标潜在区域去除干扰
42. // 点迹回溯(区域级 → 离散级)
43. 对每个最终实例分割掩膜  $S_n \in \text{DetMasks}$ :
44. FOR  $k = 1, 2, \dots, M$  do
45.  $Q^{(n)k} \leftarrow \{\text{像素}(x, y) | (x, y) \in S_n \text{ 且来源于 } I_{\text{fusion}}^k\}$ 
46.  $P_{\text{radar}}^{(n)k} \leftarrow \{p \in P_k | p \in S_n\}$ 
//分割区域内雷达投影点集合
47. end FOR
48.  $\text{Track}_n \leftarrow (Q^{(n)} \cup P_{\text{radar}}^{(n)})$ 
49. end FOR
50. RETURN  $\text{DetMasks}, \text{Track}_n$ 

```

8 试验验证

本试验验证包括五个部分:试验条件、直线运动目标检测试验分析、转弯机动目标检测试验分析、消融试验分析以及对比试验分析。

8.1 试验条件

为对本算法有效性进行检验,我团队搭建了海上微弱目标雷达-红外多视角协同探测系统,在具有海杂波、岛屿等干扰的复杂背景下,采集了雷达基带回波数据、雷达原始点迹数据、红外图像数据,基于此构建了用于智能 TBD 检测的数据集。该数据集专注于小型船只、快艇等低可探测海上目标,图 11 为试验场地实拍图。

数据集中目标为海上小型船只,背景干扰包括红外图像中的岛屿、海鸟、浮漂干扰物及雷达回波数据中的海杂波干扰。红外图像数据由 FLIR X6530SC 红外相机采集,相机工作波段为 3.0~5.0 μm ,相机坐标为 (120.033 298°, 35.797 54°, 15.12 m),焦距为 50 mm,可



图 11 青岛灵山岛海域试验场地实拍图

在 5 km 内成像,相机安装在固定支架上,轴向视角为 98°(正北方向为 0°),面向关注海域。雷达数据由 Ku 波段雷达系统采集,雷达带宽为 50 MHz,距离分辨率 3 m,坐标为 (120.033 130°, 35.797 606°, 15.54 m),轴向视角 100°(正北方向为 0°),雷达系统输出的量测信息包括目标幅度、方位角与距离。

最终所构建数据集中包括 2 849 张红外图像、2 849 帧雷达数据。其中目标直线运动共有两个场景:(1)场景 A,包含岛屿、船只和海鸟,共 509 帧红外图像、509 帧雷达数据;(2)场景 B,包含岛屿、船只和浮漂,共 436 帧红外图像、436 帧雷达数据。目标机动转弯场景包含 1 904 帧红外图像、1 904 帧雷达数据。


算法模型训练的设备配置包括 NVIDIA GeForce RTX 3060 Laptop 独立显卡、12 th Gen Intel(R) Core(TM) i9-12900H 处理器,操作系统为 Ubuntu 22.04,Python 环境版本为 3.10,深度学习框架 PyTorch 的版本为 2.5.1。AMSFE-YOLOv11 网络训练参数设置如下:输入图像尺寸设置为 1 024 × 1 024,总训练轮数 epochs 设置为 500,批次大小设置为 8,优化器选用基于梯度下降法的 AdamW 方法,初始学习率设置为 0.01。

8.2 直线运动目标检测试验分析


如上文所述,本节试验包括两类场景,对直线运动目标的雷达-红外融合图像进行目标检测。检测所用直线运动场景 10 帧累积融合图像共 791 幅,其中训练集 553 幅,测试集 238 幅。不同场景下的单帧红外图像、经过低门限处理后的单帧雷达 P 显图如图 12 所示。

图 12(a)与图 12(c)分别是场景 A 和场景 B 下的经过低门限处理后的单帧雷达 P 显图,P 显图包含了岛屿回波、目标舰船回波,以及大片的海杂波。图 12(b)与图 12(d)分别是场景 A 和场景 B 下的单帧红外图像,其中部分船只目标仅占据了 3~4 个像素,并且场景 A 中存在海鸟干扰,场景 B 中存在浮漂干扰,并且浮漂形态呈多点线性分布,多帧累积后的海鸟运动轨迹与小型船只运动轨迹相似,同时像素数较少,难以从形态上将其与小型船只分辨,会对目标检测造成干扰。


图 13 是两种场景下直线运动目标单帧雷达-红外虚拟融合图,红色像素点表示雷达在红外图像中的投影点。




(a) 场景 A 雷达 P 显图



(b) 场景 A 红外图像




(c) 场景 B 雷达 P 显图




(d) 场景 B 红外图像

图 12 直线运动不同场景下的雷达 P 显图与红外图像

图 14 是直线运动场景 A、B 其中一组 10 帧累积雷达-红外融合图像与目标潜在区域。绿色方框内为目标潜在区域,可知场景 A 10 帧累积融合图像的目标潜在区域分为两部分,单独的小岛屿区域和两艘目标舰船



(a) 场景 A 单帧雷达-红外虚拟融合图



(b) 场景 B 单帧雷达-红外虚拟融合图

图 13 直线运动目标单帧雷达-红外虚拟融合图

与大岛屿共同存在的区域;场景 B 10 帧累积融合图像的目标潜在区域分为四部分,两艘目标舰船区域、小岛屿区域以及大岛屿区域。从目标潜在区域的划定结果可以发现,海鸟、浮漂、大部分海杂波等背景干扰均被划分在目标潜在区域之外,从而被有效抑制。

图 15 是直线运动不同场景下某一组 10 帧累积的雷达-红外融合图像检测结果。图 15(a)是场景 A 融合图像初步检测结果,初步检测中,共检测出三个目标,包括两个目标舰船以及一个海鸟误检,岛屿由于形态与目标舰船不一致,通过网络的初步检测即可剔除;图 15(c)是结合图 14(c)的目标潜在区域后的检测结果,剔除了海鸟干扰;图 15(e)是场景 A 点迹回溯结果,通过点迹回溯操作,将图 15(c)的检测结果——两段连续目标区域,进一步还原为真实场景中的离散像素点分布;图 15(b)是场景 B 融合图像初步检测结果,初步检测中,共检测出三个目标,包括两个目标舰船以及一个浮漂误检,岛屿通过网络初步检测即可剔除;图 15(d)是结合图 14(d)的目标潜在区域后的检测结果,剔除了浮漂干扰;图 15(f)是场景 B 点迹回溯结果,将图 15(d)的两段连续目标区域还原为离散像素点分布。

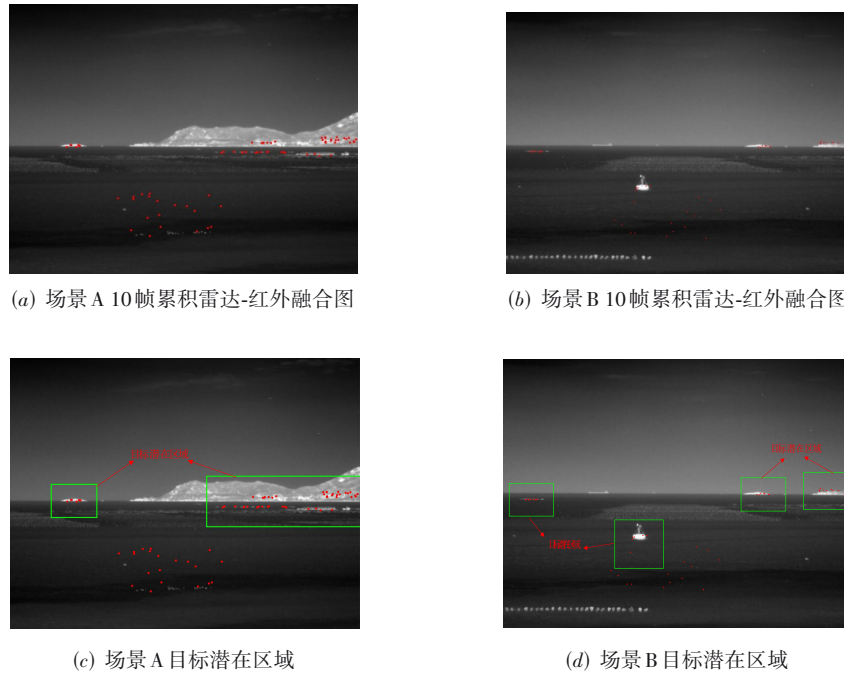


图 14 直线运动不同场景 10 帧累积融合图像与目标潜在区域

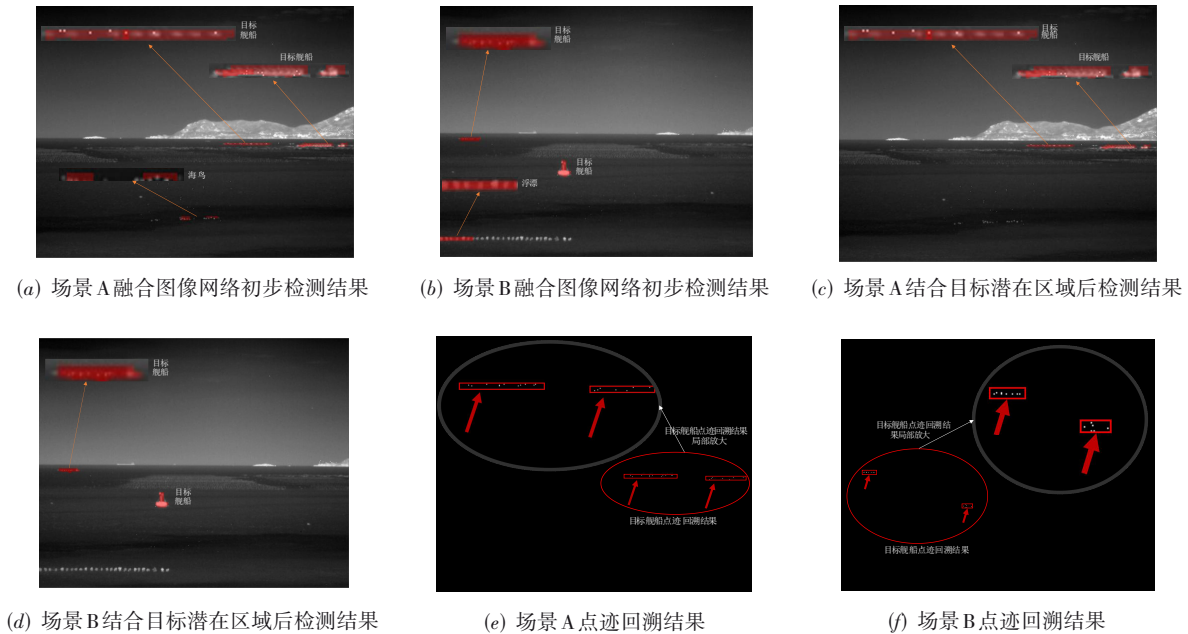


图 15 直线运动不同场景下的雷达-红外多帧累积融合图像检测结果


为体现本文所提雷达-红外多传感器融合 TBD 算法的优势,下面将其与单独的雷达、红外传感器检测结果进行对比. 红外图像检测中,所用的数据集为 10 帧累积的原始红外图像. 检测结果如下.

图 16 是两种场景下 10 帧累积后的红外图像,可见经过 10 帧累积后,场景 A 中的海鸟也呈现与船只轨迹相似的运动轨迹,并且在红外图像中形态与小型船只


接近,场景 B 中的浮漂形态与远距离舰船相似,此时海鸟和浮漂都会对目标检测造成干扰.

图 17 是对 10 帧累积红外图像进行检测的结果,可以看到红外图像检测中将海鸟和浮漂都误检为目标,由于没有结合雷达量测数据,无法剔除误检.

图 18 为单纯基于雷达 P 显图数据 10 帧累积后的结果,可见海杂波区域和岛屿区域的雷达回波较密集,形




(a) 场景 A 10 帧累积红外图像




(b) 场景 B 10 帧累积红外图像

图 16 直线运动不同场景 10 帧累积红外图像



(a) 场景 A 红外图像检测结果



(b) 场景 B 红外图像检测结果


图 17 直线运动不同场景红外图像检测结果

成了类似于目标舰船的轨迹特征。


图 19 为直线运动不同场景雷达 P 显图 10 帧累积后的检测结果,红色检测框区域即为检测结果,海杂波和岛屿区域均有部分被误检为目标,造成大量虚警。

经过 30 次试验,分别得到直线运动场景下雷达-红外融合、红外、雷达的目标检测概率、虚警率结果,如图 20 所示。

图 20 展示了直线运动场景 A 和场景 B 下对三种不




(a) 场景 A 10 帧累积雷达 P 显图




(b) 场景 B 10 帧累积雷达 P 显图

图 18 直线运动不同场景 10 帧累积雷达 P 显图




(a) 场景 A 雷达 P 显图检测结果




(b) 场景 B 雷达 P 显图检测结果

图 19 直线运动不同场景雷达 P 显图检测结果

同情况的检测结果.从检测概率来看,雷达-红外融合检测表现出显著的性能优势,在场景 A 和场景 B 中分别达到 96.8% 和 94.7% 的检测概率,较单一红外的 88% 和 86.3% 检测概率,分别提升了 8.8 和 8.4 个百分点,较单一雷达图像的 85.3% 和 85%,分别提升了 11.5 和 9.7 个百分点.这一结果表明,融合算法能够有效整合异质传感器的互补信息,增强系统对低可观测目标的探测能力。



(a) 检测概率



(b) 虚警率

图 20 直线运动检测概率与虚警率对比


在虚警抑制能力方面,融合检测展现出更为突出的优越性.融合检测的虚警率仅为0.002 3(场景A)和0.005 2(场景B),相较于红外0.107(场景A)和0.094(场景B)的虚警率低了一个数量级,相较于雷达0.46(场景A)和0.32(场景B)的虚警率低了近两个数量级,抑制率分别达到99.5%和98.4%.值得注意的是,雷达数据虽然能够提供目标的距离-方位信息,但其缺乏目标形态和纹理信息,导致网络能够学习的特征有限,在复杂背景下容易产生较高的虚警.而融合图像检测通过建立雷达量测与红外特征的联合判决准则,利用多源信息的交叉验证机制,有效抑制了各传感器独立工作时的虚假目标,实现了检测性能的提高.上述试验结果充分验证了所提出的雷达-红外融合检测策略在提升检测概率和降低虚警率两个关键性能指标上,相较于单个传感器具有独特优势.

8.3 转弯机动目标检测试验分析


本节主要验证本文方法对海上转弯机动微弱目标的检测性能,所用转弯机动累积融合图像共1 679幅,其中训练集1 175幅,测试集504幅.目标转弯机动情况下经过低门限处理后的单帧雷达P显图与单帧红外图像如图21所示.

单帧雷达P显图中,包含岛屿回波、目标舰船回波和大量的海杂波.单帧红外图像中,包含一串浮漂、两艘目标舰船以及岛屿.

图22是转弯运动单帧雷达-红外融合图像,其中雷达量测信息投影区域为两艘小艇目标区域、岛屿区域



(a) 转弯运动单帧雷达P显图



(b) 转弯运动单帧红外图像

图 21 目标转弯机动情况下雷达P显图与单帧红外图像




图 22 转弯运动单帧雷达-红外融合图


以及海杂波区域.

图23是目标转弯机动情况下10帧累积雷达-红外融合图像与目标潜在区域划分结果.由图23(b)可见,累积融合图像中目标潜在区域分为三个舰船区域和三个岛屿区域六部分.


图24(a)是转弯运动融合图像初步检测结果,初步检测结果中,共检测出三个目标,包括两个目标舰船以及一个浮漂误检,岛屿通过网络初步检测即可剔除;图24(b)是结合图23(b)的目标潜在区域后的检测结果,剔除了浮漂干扰;图24(c)是转弯运动点迹回溯结果,通过点迹回溯操作,将图24(b)的检测结果——两段连续目标区域,进一步还原为真实场景中的离散像素点分布.

为验证目标机动情况下本文所提融合检测方法相较于单传感器检测的优势,下面将其与红外、雷达单传感器的检测情况进行对比.

图25是10帧累积后的红外图像,浮漂在红外图像中形态与小型船只接近,会对目标检测造成干扰.




(a) 转弯运动雷达-红外融合图像




(b) 转弯运动目标潜在区域


图 23 转弯运动 10 帧累积融合图像与目标潜在区域



(a) 转弯运动融合图像网络初步检测结果



(b) 转弯运动结合目标潜在区域后检测结果



(c) 转弯运动点迹回溯结果

图 24 转弯运动融合图像检测结果




图 25 转弯运动 10 帧累积红外图像

图 26 是对 10 帧累积红外图像的检测结果,可以看到检测结果将浮漂误检为目标,并且由于没有结合雷达量测数据,很难剔除误检.




图 26 转弯运动红外图像检测结果

图 27 为目标转弯机动情况下 10 帧累积雷达 P 显图,图 28 为雷达 TBD 检测结果,可见有部分岛屿区域和海杂波被误检为目标,且无法剔除.




图 27 目标转弯机动情况下 10 帧累积雷达 P 显图




图 28 转弯运动情况下雷达 TBD 检测结果

图 29 为转弯运动场景下,雷达-红外融合、红外、雷达的检测概率、虚警率对比结果. 图 29 呈现了目标转弯机动场景下三种情况下的检测结果. 试验数据表明,雷达-红外融合检测在目标机动条件下同样展现出很大




图 29 转弯运动检测概率与虚警率对比

的优势.

从检测概率可见,融合检测概率达到96.5%,显著高于单一雷达83.6%的检测概率和单一红外的检测概率,分别提升了12.9和8.7个百分点.这一结果表明,在目标做机动运动下,融合检测能够有效克服单一传感器在动态场景下的检测局限性,通过多源信息的互补机制,有效提升了系统对机动目标的检测能力.

在虚警抑制性能方面,融合检测虚警率仅为0.0029,较单一雷达的0.21降低了两个数量级,较单一红外的0.033降低了一个数量级.这一显著改善主要得益于雷达和红外传感器量测的相互比对和互补,以及本文提出的目标潜在区域划定机制,从而有效滤除了背景干扰.

8.4 消融试验分析

为评估AFEM模块、SimAM模块和MDCR模块在本文目标检测中的实际效果,本文设计了消融试验,具体而言,试验分别构建五种模型.

基础模型:YOLOv11网络结构.

改进模型1:在YOLOv11基础上引入SimAM模块.

改进模型2:在YOLOv11基础上引入MDCR模块.

改进模型3:在YOLOv11基础上引入AFEM模块.

改进模型4:在YOLOv11基础上同时引入AFEM模块、SimAM模块与MDCR模块.

上述五种模型均在相同数据集、相同训练参数及相同设备下进行训练与测试.图30展示了在直线运动场景与转弯运动场景下,五种模型对雷达-红外信息融合图像的目标检测概率与虚警率.由图30可见,基础

YOLOv11网络在复杂海面背景下的检测性能有限,直线运动场景A、B的检测概率分别为0.676和0.664,转弯运动为0.698,虚警率为0.016~0.078,说明其对微弱目标的特征提取与背景抑制能力不足.当单独引入SimAM模块后,检测概率提升至0.744(场景A)、0.707(场景B)和0.752(转弯场景),虚警率降至0.012~0.047之间.这表明SimAM通过像素级显著性权重建模,能够增强微弱目标边缘响应与纹理特征,使网络在低对比度条件下具备更强的显著性提取能力.单独引入MDCR模块后,检测概率提升至0.767(场景A)、0.723(场景B)和0.751(转弯场景),虚警率降至0.0087~0.026.该模块利用多膨胀卷积结构捕获不同尺度下的目标空时相关性特征,强化了对多帧累积航迹形态的建模能力.单独引入AFEM模块后,检测概率提升至0.830(场景A)、0.890(场景B)和0.893(转弯场景),虚警率降低至0.058~0.016.AFEM通过联合空间与通道注意力机制自适应增强目标相关区域,显著改善了目标与背景的区分度.当三种模块(AFEM、SimAM、MDCR)联合使用时,检测概率分别达到0.968、0.947和0.965,虚警率降低至0.0023~0.0052.

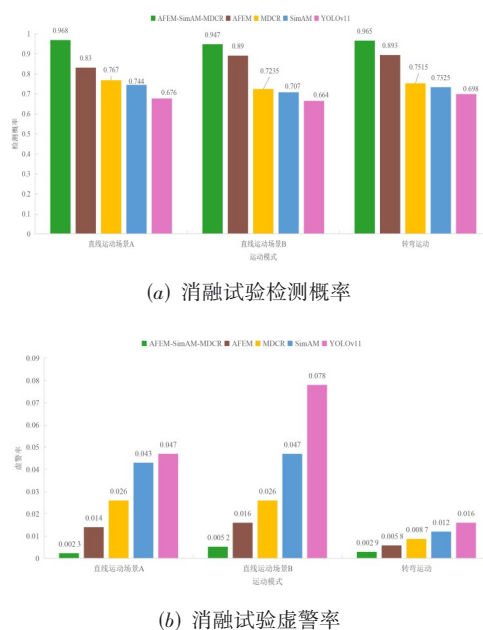


图 30 消融试验检测概率与虚警率

试验结果表明,AFEM模块、SimAM模块与MDCR模块在微弱目标检测任务中发挥了积极作用,验证了其在提升检测性能和抑制虚警方面的有效性.这些模块的引入有效改善了目标检测的精度与稳定性,为复杂海面环境下的微弱机动目标检测提供了有力支持.

8.5 对比试验分析

为进一步验证所提方法的有效性,本文将提出的

AMSFE-YOLOv11 网络检测算法与文献[15]所提出的检测算法以及文献[11]中基于 Hough 变换的检测算法进行了对比试验. 三种算法均在相同的融合图像数据集下进行评估, 以保证结果的公平性. 试验结果如表 2 所示.

表 2 本文方法与文献[15]、文献[11]方法的对比试验结果 单位:%

| 检测方法 | 运动模式 | 检测概率 | 虚警率 |
|-------------------------|----------|-------|-------|
| AMSFE-YOLOv11 网络检测算法 | 直线运动场景 A | 96.80 | 0.23 |
| | 直线运动场景 B | 94.70 | 0.52 |
| | 转弯运动 | 96.50 | 0.29 |
| 文献[15]的检测算法 | 直线运动场景 A | 79.90 | 1.00 |
| | 直线运动场景 B | 76.00 | 0.95 |
| | 转弯运动 | 69.90 | 0.91 |
| 文献[11]的检测算法 | 直线运动场景 A | 28.63 | 20.50 |
| | 直线运动场景 B | 36.64 | 41.88 |
| | 转弯运动 | 21.35 | 44.95 |

对比试验结果表明, 本文提出的 AMSFE-YOLOv11 网络在不同运动场景下均表现出显著优势, 其检测概率在直线和转弯运动条件下均稳定维持在 94% 以上, 同时虚警率始终控制在 0.60% 以下, 展现出较强的稳定性与鲁棒性. 相比之下, 文献[15]所提出的检测方法在三种运动场景中的检测概率仅为 69.90%~79.90%, 虚警率接近 1%; 文献[11]方法在复杂背景下的表现更不佳, 其检测概率普遍低于 40%, 虚警率则高达 20%~45%, 存在明显的检测不稳定性与误检率偏高问题.

9 结束语

本文针对复杂海面背景下小型船只目标检测难题, 提出了雷达-红外多视角协同智能 TBD 方法. 该方法首先通过雷达低门限预处理去除部分干扰的同时保留潜在目标信息, 之后通过异构数据空间映射处理实现雷达-红外像素级融合, 随后, 采用最大值多帧累积策略增强目标空时相关性, 构建目标潜在区域, 有效抑制海鸟、浮漂等干扰. 在网络架构上, 通过引入 AFEM、SimAM 和 MDCR 三个模块改进 YOLOv11, 提出 AMSFE-YOLOv11 网络, 显著提升了对低对比度微弱目标的特征表征能力.

实测数据集验证表明, 在直线和转弯运动场景下, 融合检测的检测概率达 94.7%~96.8%, 虚警率控制在 0.23%~0.52%, 相较于单一红外(检测概率<88%, 虚警率>3.3%)和雷达检测(检测概率<85.3%, 虚警率>21%)均有大幅提升. 消融试验表明, 引入改进模块可使检测概率提升约 27 个百分点. 与 Hough 变换方法相比, 检测概率提高约 60 个百分点, 虚警率降低超过 20 个百分

点, 充分验证了融合策略与深度学习结合的 TBD 算法的有效性和优越性.

然而, 本研究仍存在一定局限性: 其一, 试验场景尚未充分验证算法在多种气象条件下的检测稳定性; 其二, 网络模型的训练仍依赖大规模标注数据集.

针对上述问题, 未来研究将从两个方面展开: 一是进一步拓展试验至复杂气象环境, 以提升算法在恶劣条件下的检测可靠性; 二是引入自监督学习与生成式数据增强策略, 降低对标注样本的依赖, 实现小样本条件下的高效智能检测.

参考文献

- [1] WANG Z X, XIN Z H, LIAO G S, et al. Land-sea target detection and recognition in SAR image based on non-local channel attention network[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 5237316.
- [2] WANG J G, LI S B. Maritime radar target detection in sea clutter based on CNN with dual-perspective attention[J]. IEEE Geoscience and Remote Sensing Letters, 2023, 20: 3500405.
- [3] DENG H M, ZHANG Y. FMR-YOLO: Infrared ship rotating target detection based on synthetic fog and multiscale weighted feature fusion[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 5001717.
- [4] VENKATARAMAN K, NGUYEN S T, BATEMAN L. Optimised scan-to-scan integration techniques for low observable target detection in sea clutter[C]//2018 International Conference on Radar. Piscataway: IEEE, 2018: 1-4.
- [5] 许述文, 白晓惠, 郭子薰, 等. 海杂波背景下雷达目标特征检测方法的现状与展望[J]. 雷达学报, 2020, 9(4): 684-714.
- [6] XU S W, BAI X H, GUO Z X, et al. Status and prospects of feature-based detection methods for floating targets on the sea surface[J]. Journal of Radars, 2020, 9(4): 684-714. (in Chinese)
- [6] 陆源, 宋杰, 熊伟. 非合作双基地雷达弱目标 KCF-TBD 方法[J]. 雷达科学与技术, 2023, 21(6): 637-644.
- [7] LU Y, SONG J, XIONG W. Non-cooperative bistatic radar weak target KCF-TBD method[J]. Radar Science and Technology, 2023, 21(6): 637-644. (in Chinese)
- [7] LIANG M C, KROPFREITER T, MEYER F. A BP method for track-before-detect[J]. IEEE Signal Processing Letters, 2023, 30: 1137-1141.
- [8] 包中华, 卢建斌, 田永华, 等. 密集杂波背景下雷达微弱海面目标的修正 Hough 变换 TBD 检测新方法[J]. 电子学报, 2022, 50(7): 1735-1743.

- BAO Z H, LU J B, TIAN Y H, et al. A novel radar TBD detection approach for weak marine targets in dense clutter based on modified Hough transform[J]. *Acta Electronica Sinica*, 2022, 50(7): 1735-1743. (in Chinese)
- [9] 柳超, 孙进平, 袁常顺, 等. Geodesic流多伯努利检测前跟踪方法[J]. *电子学报*, 2020, 48(7): 1375-1379.
- LIU C, SUN J P, YUAN C S, et al. Multi-bernoulli track-before-detect method with Geodesic flow[J]. *Acta Electronica Sinica*, 2020, 48(7): 1375-1379. (in Chinese)
- [10] WU X H, DING J R, WANG Z Y, et al. Dynamic programming-based track-before-detect algorithm for weak maneuvering targets in range-Doppler plane[J]. *Remote Sensing*, 2024, 16(14): 2639.
- [11] WEI L L, ZHANG X L, FAN L. A TBD algorithm based on improved Randomized Hough Transform for dim target detection[C]//2010 2nd International Conference on Signal Processing Systems. Piscataway: IEEE, 2010: V2-241-V2-245.
- [12] CIOCARLAN A, LE HEGARAT-MASCLE S, LEFEBVRE S, et al. A contrario paradigm for yolo-based infrared small target detection[C]//ICASSP 2024 - 2024 IEEE International Conference on Acoustics, Speech and Signal Processing. Piscataway: IEEE, 2024: 5630-5634.
- [13] 王坤, 丁麒龙. 利用自适应融合和混合锚检测器的遥感图像小目标检测算法[J]. *电子与信息学报*, 2024, 46(7): 2942-2951.
- WANG K, DING Q L. Remote sensing images small object detection algorithm with adaptive fusion and hybrid anchor detector[J]. *Journal of Electronics & Information Technology*, 2024, 46(7): 2942-2951. (in Chinese)
- [14] 宣岁寒, 罗印升, 宋伟. 基于改进RT-DETR的航拍图像小目标检测算法[J]. *电光与控制*, 2025, 32(4): 44-51.
- XUAN S H, LUO Y S, SONG W. A small target detection algorithm in aerial images based on improved RT-DETR[J]. *Electronics Optics & Control*, 2025, 32(4): 44-51. (in Chinese)
- [15] 武星蕊, 彭锐晖, 孙殿星, 等. 基于TransUNet的机动微弱目标智能检测前跟踪算法[J]. *航空学报*, 2024, 45(12): 254-268.
- WU X R, PENG R H, SUN D X, et al. Intelligent TBD algorithm for maneuvering weak targets based on TransUNet[J]. *Acta Aeronautica et Astronautica Sinica*, 2024, 45(12): 254-268. (in Chinese)
- [16] 熊光明, 罗震, 孙冬, 等. 基于红外相机和毫米波雷达融合的烟雾遮挡无人驾驶车辆目标检测与跟踪[J]. *兵工学报*, 2024, 45(3): 893-906.
- XIONG G M, LUO Z, SUN D, et al. Object detection and tracking for unmanned vehicles based on fusion of infrared camera and MMW radar in smoke-obscured environment[J]. *Acta Armamentarii*, 2024, 45(3): 893-906. (in Chinese)
- [17] 常天庆, 张杰, 赵立阳, 等. 基于可见光与红外图像融合的装甲目标检测算法[J]. *兵工学报*, 2024, 45(7): 2085-2096.
- CHANG T Q, ZHANG J, ZHAO L Y, et al. Research on armored vehicle detection algorithm based on visible and infrared image fusion[J]. *Acta Armamentarii*, 2024, 45(7): 2085-2096. (in Chinese)
- [18] 汪进中, 戴顺, 张秀伟, 等. 无人机视角多源目标检测数据集 UAV-RGBT 及算法基准[J]. *电子学报*, 2025, 53(3): 686-704.
- WANG J Z, DAI S, ZHANG X W, et al. UAV-RGBT multispectral object detection dataset and algorithm benchmark[J]. *Acta Electronica Sinica*, 2025, 53(3): 686-704. (in Chinese)
- [19] VINCENTY T. Direct and inverse solutions of geodesics on the ellipsoid with application of nested equations[J]. *Survey Review*, 1975, 23(176): 88-93.
- [20] BANGARE S L, DUBAL A, BANGARE P S, et al. Reviewing otsu's method for image thresholding[J]. *International Journal of Applied Engineering Research*, 2015, 10(9): 21777-21783.
- [21] KHANAM R, HUSSAIN M. YOLOv11: An overview of the key architectural enhancements[EB/OL]. (2024-10-23)[2025-12-03]. <https://arxiv.org/abs/2410.17725>.
- [22] WANG C S, SONG X Q, WANG J, et al. An improved YOLOv11 algorithm for small object detection in UAV images[J]. *Signal, Image and Video Processing*, 2025, 19(6): 507.
- [23] YANG L, ZHANG R Y, LI L, et al. Simam: A simple, parameter-free attention module for convolutional neural networks[C]//Proceedings of the 38th International Conference on Machine Learning. Cambridge: PMLR, 2021, 139: 11863-11874.
- [24] XU S B, ZHENG S C, XU W H, et al. HCF-net: Hierarchical context fusion network for infrared small object detection[C]//2024 IEEE International Conference on Multimedia and Expo. Piscataway: IEEE, 2024: 1-6.
- [25] LONG W, ZHANG Y J, CUI Z W, et al. Threshold attention network for semantic segmentation of remote sensing images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 4600312.

[26] YANG X, MOHAMED A S A. Gaussian-based R-CNN with large selective kernel for rotated object detection in

remote sensing images[J]. Neurocomputing, 2025, 620: 129248.

作者简介



孙殿星 男,1983年6月出生于黑龙江省伊春市.现为哈尔滨工程大学信息与通信工程学院教授.主要研究方向为雷达信号处理、雷达数据处理以及雷达抗干扰.

E-mail: sundianxing@hrbeu.edu.cn



谭顺成 男,1985年12月出生于湖南省湘潭市.现为海军航空大学副教授.主要研究方向为雷达信号处理、雷达数据处理、雷达抗干扰以及微弱目标检测.

E-mail: tanshuncheng85@sina.com



黄亚圣 男,2001年12月出生于江西省赣州市.现为哈尔滨工程大学信息与通信工程学院博士研究生.主要研究方向为雷达信号处理、多源信息融合以及智能检测.

E-mail: huangyasheng@hrbeu.edu.cn



王国宏 男,1963年10月出生于山西省沁水县.现为海军航空大学教授、博士生导师.主要研究方向为多源信息融合、雷达数据处理、雷达抗干扰以及微弱目标检测.

E-mail: wangguohong@vip.sina.com



彭锐晖 男,1979年9月出生于湖北省武汉市.现为哈尔滨工程大学信息与通信工程学院教授.主要研究方向为雷达信号处理、雷达目标特性以及雷达抗干扰.中国电子学会会员编号:

E190183282M.

E-mail: pengruihui@hrbeu.edu.cn