

红外低对比度海冰图像边缘-全局协同增强检测

杜浩铖 陶淑苹

Edge-global collaborative enhancement detection for low-contrast infrared sea ice images

DU Hao-cheng, TAO Shu-ping

引用本文:

杜浩铖, 陶淑苹. 红外低对比度海冰图像边缘-全局协同增强检测[J]. 中国光学, 优先发表. doi: 10.3724/CO.2026-0093

DU Hao-cheng, TAO Shu-ping. Edge-global collaborative enhancement detection for low-contrast infrared sea ice images[J]. *Chinese Optics*, In press. doi: 10.3724/CO.2026-0093

在线阅读 View online: <https://doi.org/10.3724/CO.2026-0093>

您可能感兴趣的其他文章

Articles you may be interested in

文章编号 2097-1842(xxxx)x-0001-12

红外低对比度海冰图像边缘-全局协同增强检测

杜浩铖, 陶淑苹*

(中国科学院长春光学精密机械与物理研究所, 吉林 长春 130033;
中国科学院大学, 北京 100049)

摘要: 目的: 红外成像因优异的抗雾干扰能力, 是恶劣气象下海冰连续监测的核心光学传感模态。针对红外海冰图像中目标与背景灰度差异微弱、边缘模糊的低对比度检测难题, 提出一种边缘-全局协同增强检测方法。方法: 以 YOLOv7(You Only Look Once version 7) 为基础框架, 在浅层 ELAN 模块中嵌入 Sobel 轮廓提取模块, 通过水平与垂直方向梯度提取及自适应融合, 强化海冰边缘的光学梯度特征; 在深层 ELAN 模块中引入大核卷积(LKC)模块, 采用主分支瓶颈式大核卷积与短接分支 3×3 卷积的双分支并行设计, 在扩大感受野的同时保留局部细节, 将小目标光学斑块与全局辐射背景进行关联建模。结果: 实验基于多气象场景红外海冰数据集, 以原始 YOLOv7 为基线, 构建仅加 Sobel、仅加 LKC 及双模块融合三组对照模型, 选取精确率、召回率、mAP@0.5 和计算量四项指标进行评价。浓雾条件下, 所提方法召回率达 0.674, mAP@0.5 达 0.671, 较基线分别提升 9.3 个百分点和 7.7 个百分点; 全混合气象测试集上召回率达 0.63, mAP@0.5 达 0.627。消融实验表明双模块协同工作时各项指标最优, 计算量仅从 103.2 GFLOPs 微增至 103.5 GFLOPs。结论: 所提方法通过边缘梯度增强与全局背景关联建模的协同, 显著提升了低对比度红外海冰目标的检测精度与鲁棒性, 基本满足恶劣气象下实时红外海冰监测的需求。

关键词: 红外海冰图像; 低对比度目标检测; 边缘梯度增强; 大核卷积; 光学特征提取

中图分类号: TP394.1; TH691.9 文献标志码: A doi: 10.3724/CO.2026-0093 CSTR: 32171.14.CO.2026-0093

Edge-global collaborative enhancement detection for low-contrast infrared sea ice images

DU Hao-cheng, TAO Shu-ping*

(Changchun Institute of Optics, Fine Mechanics and Physics, Chinese Academy of
Sciences, Changchun Jilin, 130033;

University of Chinese Academy of Sciences, Beijing, 100049)

* Corresponding author, E-mail: taoshuping11@sina.com

Abstract: **Objective:** Infrared imaging serves as a core sensing modality for sea ice monitoring under severe weather conditions, owing to its excellent fog-penetration capability that supports continuous observation. However, low contrast and blurred edges remain key challenges in infrared sea ice imagery. **Method:** This

收稿日期: 2026-05-26; 修订日期: xxxx-xx-xx

基金项目: 吉林省科技发展计划项目 (No. 20240302018GX); 吉林省科技发展计划项目 (创新能力建设) (No. 20250402007ZP)

Supported by Jilin Provincial Science and Technology Development Plan Project (No. 20240302018GX); Jilin Provincial Science and Technology Development Plan Project (Innovation Capacity Construction) (No. 20250402007ZP)

paper proposes an edge-global collaborative enhancement detection method built upon the YOLOv7 (You Only Look Once version 7) framework. A Sobel contour extraction module is embedded in the shallow ELAN blocks, which extracts horizontal and vertical gradients and performs adaptive fusion to enhance the edge gradient features of sea ice boundaries. A Large Kernel Convolution (LKC) module is then added to the deep ELAN blocks, adopting a dual-branch parallel complementary design: the main bottleneck branch expands the network's receptive field, while the short-connected 3×3 convolution branch preserves fine local details of targets and correlates local image patches with the global radiative background. **Result:** Experiments are conducted on a multi-weather infrared sea ice dataset, with the original YOLOv7 set as the baseline for comparison. Three control models are constructed: Sobel-only, LKC-only, and dual-module. Four metrics are adopted for evaluation: precision, recall, mAP@0.5, and computational cost. Under dense fog conditions, the proposed method achieves a recall of 0.674 and an mAP@0.5 of 0.671, corresponding to improvements of 9.3 and 7.7 percentage points over the baseline, respectively. On the mixed-weather test set, recall reaches 0.63 and mAP@0.5 reaches 0.627. Ablation experiments verify that the dual-module model delivers the best performance across all metrics, with only a slight increase in computational cost from 103.2 GFLOPs to 103.5 GFLOPs. **Conclusion:** By integrating edge enhancement and global background modeling, the proposed method significantly improves the detection accuracy of low-contrast sea ice targets and enhances model robustness in harsh weather scenarios, and can effectively meet the requirements of real-time sea ice monitoring under adverse weather conditions.

Key words: infrared sea ice image; low-contrast target detection; edge gradient enhancement; large kernel convolution; optical feature extraction

1 引言

海冰是极地及中高纬度海域重要的海洋灾害源,因此海冰的精确检测对冰区舰船航行安全、极地气候研究都具有直接而重大的意义^[1]。船载红外成像由于工作波长较长,对雾滴的散射效应极弱,因而能有效穿透海雾等恶劣气象,又能可靠地保留被测目标的热辐射特征,因此成为恶劣气象条件下海冰连续监测的核心光学传感模态^[2]。

然而,红外海冰图像存在目标与海水背景灰度差异微弱、边缘模糊等典型的问题。从光学物理机制可以予以解释:晴天太阳直射时海冰表面升温、海水相对低温,二者温差很大,因此红外热图像中目标与背景的对比度很高。与此形成对照的是,浓雾遮挡太阳直射辐射之后,海冰与海水表面温度趋于一致,目标与背景的灰度梯度被极大压缩,导致形成极低对比度场景^[3-4]。更重要的是,红外热成像本身的空间分辨率有限,远距离小浮冰在图像中所占像素极少,因而缺乏足够的纹

理及形状信息,信噪比极低,极易与雾粒噪声、背景杂波混淆,这也是目前红外海冰检测中的核心瓶颈。

低对比度目标的检测关键在于强化目标与背景的特征差异。传统方法中,双直方图均衡化^[5]和多尺度融合增强^[6]都利用空域对比度拉伸来改进视觉效果,但是也不可避免地引入噪声伪影,且与之后的检测任务脱离。在红外小目标检测领域, Ren 等^[7]提出了多级稀疏特征融合网络,从特征级、决策级都做了稀疏特征融合,同时引入目标全局特征进行深度联合监督训练,缓解了红外弱小目标特征稀疏的检测难题。蔚婧等^[8]提出的空频域特征融合网络 SFNet(Spatial-Frequency Network),用固有字典编码提取局部纹理,用空频查询注意力提取全局上下文,再用非对称空频特征融合策略将两者结合起来,由此弥补了现有方法忽略频域信息的不足。王伯霄等^[9]提出的难点注意力感知红外小目标检测网络,通过对粗掩码难点进行多尺度特征融合与逐像素注意力建模,有效缓解了红外小目标形状缺失、边界模糊的问

题。周卓等^[10]提出的基于多尺度空间损失和形态学特征的红外小目标检测方法, 设计了绝对空间损失函数并配合多尺度层级化监督, 有效克服了交并比损失对目标位置不敏感的问题。陈科等^[11]提出的轻量级 ERM-DETR(Enhanced Receptive field Multi-path Detection Transformer) 模型, 以轻量特征提取模块为基础, 结合注意力机制及多路径鲁棒下采样结构, 检测精度得到显著提升。此外, 赵佳乐等^[12]在红外舰船检测中通过轻量化网络与剪枝, 验证了低计算开销下红外目标高精度检测的可行性。

Tang 等^[13]提出的 IRSTD-YOLO(Infrared Small Target Detection YOLO) 将 Sobel 算子嵌入 YOLO(You Only Look Once) 框架, 通过边界提取与空间特征互补, 有效提升了红外小目标的检测性能。Sobel 算子的原理是使用相邻像素灰度差值来估计边缘强度, 其水平、垂直方向的梯度分量分别对应目标边缘的法向及切向光学变化, 二者融合可重建更完整的信息^[13]。然而, Sobel 算子主要用来增强局部边缘特征, 对远距离小目标的全局语义捕捉能力仍有明显局限。薛驰等^[14]融合背景估计与相对局部对比度, 通过背景残差图与多尺度对比度协同, 提升了低信杂比下红外弱小目标的检测稳定性。赵阳等^[15]在红外与可见光融合任务中提出基于尺度分工的协同融合原则, 验证了大尺度全局结构与局部小尺度细节协同增强的有效性。借鉴此类背景建模的特征增强思想, 本文引入大核卷积(Large Kernel Convolution, LKC)来解决感受野不足的问题。传统卷积神经网络中感受野与特征分辨率有明确的反向变化关系: 浅层特征有高分辨率, 因而有利于保留小目标的细节, 但是由于所用卷积核尺寸小, 故其感受野仅能覆盖局部区域。深层特征感受野较大, 但是经过若干次下采样之后小目标细节已经严重压缩甚至彻底丢失^[16]。大核卷积通过使用增大的核尺寸, 一次卷积覆盖更大区域, 从而减少多轮小核卷积的信息损失, 能够将局部目标与周围海水背景进行关联建模^[13]。

本文从已有方法出发, 提出了面向低对比度红外海冰图像的增强检测方法, 不同于目前单纯做边缘增强或单纯扩大感受野的诸种方法, 本文首次在 YOLOv7 框架中对二者做了分层协同

设计, 在几乎不增大计算量的前提下显著提高了低对比度海冰目标的检测性能。具体而言, 以 YOLOv7 为基础框架, 在浅层 ELAN(Efficient Layer Aggregation Network) 模块中嵌入 Sobel 轮廓提取模块, 直接、高效地提取海冰边缘的光学梯度特征, 又在深层 ELAN 模块中引入 LKC 大核卷积模块, 用双分支瓶颈式大核卷积及局部细节提取两者并行的设计, 在扩大感受野的同时尽量保留精细边缘特征, 因此双模块彼此配合、互为补充, 边缘细节与全局语义都得到充分增强, 低光学对比度场景下海冰目标的检测性能因而有效提升。

2 理论基础

2.1 红外海冰图像的低对比度光学成因

红外成像依赖目标与背景的热辐射差异。在晴天气象条件下, 太阳直射辐射使海冰表面升温较快, 海水因比热容较大升温较慢, 二者表面温度差异显著, 红外热图像中目标与背景的灰度对比度较高。当浓雾遮挡太阳直射辐射后, 海冰与海水的表面温度趋于均衡, 热辐射差异被显著压缩, 导致红外图像中目标与背景的灰度梯度降低, 形成极低对比度场景。

此外, 由于远距离小浮冰在成像平面上所占像素只有 10~20 个, 缺乏足够的纹理与形状信息, 光学特征极为稀疏, 进一步加剧了检测难度。数据集中的部分低对比度红外图像如图 1 所示。




图 1 红外子数据集部分气象图示

Fig. 1 Selected Meteorological Scenario Diagrams from the Infrared Sub-dataset

2.2 Sobel 边缘提取的光学原理

边界是目标与背景之间光学对比度变化集中的区域, 在红外图像中, 海冰边缘对应于灰度值空

间突变的位置,其梯度强度可反映局部光学对比度的大小。Sobel 算子可以有效地利用水平($Sobel_x$)与垂直($Sobel_y$)方向的梯度检测核对输入特征图进行卷积运算,分别提取边缘的法向与切向光学变化。水平方向算子用于检测垂直边缘,适合检测沿水平方向的光学变化率;垂直方向算子用于检测水平边缘,对应海冰轮廓沿垂直方向的光学变化率。边缘特征运算表达如式 (1)、(2)、(3) 所示:

$$E_x = Sobel_x(X) \quad , \quad (1)$$

$$E_y = Sobel_y(X) \quad , \quad (2)$$

$$X_s = E_x + E_y \quad , \quad (3)$$

其中, X 为输入特征图, E_x 、 E_y 分别为水平和垂直方向的边缘特征图, X_s 为融合后的边缘特征输出。网络通过学习自适应融合后的边缘特征可更完整表征海冰目标轮廓的光学结构信息。

2.3 大核卷积的全局光学关联建模

大核卷积通过增大卷积核尺寸来扩大感受野,其核心优势在于能够将局部光学斑块与更大范围的背景辐射信息进行关联建模。对于仅占 10~20 像素的远距离小浮冰,传统 3×3 卷积的感受野仅能覆盖目标局部,无法有效关联周围海水背景的光学信息;而大核卷积通过单次操作覆盖更广的空间范围,能够整合小目标与周边海水背景的全局辐射差异,更有利于增强目标光学特征的显著性^[13]。

然而,由于单纯的大核卷积存在精细特征表征能力不足、容易忽略海冰局部边缘及纹理细节的问题,因此本文采用了双分支并行设计:主分支用 1×1 卷积降维、大核卷积提取全局信息、再用 1×1 卷积升维的瓶颈式结构,在控制计算量的前提下扩大感受野,捕捉全局上下文光学特征。参考 ResNet(Residual Network) 的设计思想,短接的残差分支保留标准 3×3 卷积,专注于局部细节特征提取,与大核主分支形成有效互补。双分支数据融合后的特征图经过修正线性单元(Rectified Linear Unit, ReLU) 激活函数引入非线性变换,增强网络的表达能力,最终输出包含海冰多尺度、多维度信息的全局特征图。

该特征图同时融合了海冰的整体形态特征

(来自大核分支)与精细边缘特征(来自短接分支),语义信息更加丰富,能够为后续的特征提取与目标检测头提供更具判别力的输入。模块结构图如图 2 所示。模块中深度可分离卷积的采用进一步降低了计算复杂度,使该设计在不显著增加计算成本的前提下,同时兼顾全局语义与局部细节的光学特征建模。




图 2 LKC 模块结构图

Fig. 2 LKC Module Structure Diagram

3 关键改进方法

3.1 整体网络构型

以 YOLOv7 为基础检测框架,网络整体由骨干网络、颈部和检测头三大部件构成。骨干网络保留 YOLOv7 经典的多尺度特征提取逻辑,核心改进在于:在浅层第 2 个 ELAN 模块中嵌入 Sobel 轮廓提取模块,在深层第 4 个 ELAN 模块中嵌入 LKC 大核卷积模块。浅层 ELAN 模块特征图分辨率较高,Sobel 算子能够精确捕捉海冰边缘的细微光学梯度信息,且其固定权重的计算开销极小;深层特征图分辨率较低,大核卷积的计算开销相对可控,且深层语义信息需要更广泛的上下文关联,LKC 的双分支设计能够在扩大感

受野的同时保留局部细节信息。检测头部分保留 YOLOv7 原生结构。网络整体结构图如图 5 所示。模块放置位置均经过理论分析和实验验证。如 Sobel 在原特征图上计算防止 CBS(Conv-BatchNorm-SiLU) 模块降维影响因此放在旁路, 而在 CBS 降维之后, 可大幅降低 LKC 的计算量, 且放在主分支前端可指导后续所有小核卷积的特征学习, 故 LKC 模块置于 CBS 模块之后的主分支上。

需要指出的是, YOLOv7 深层卷积特征经过多次下采样后空间分辨率显著降低, 偏重高级语义信息, 在低对比度场景下难以实现边界框与海冰目标不规则轮廓的精准贴合, 容易出现定位偏移。本文在浅层第 2 个 ELAN 模块中嵌入 Sobel 轮廓提取模块, 正是针对这一不足。浅层特征图分辨率较高, Sobel 算子能够在此分辨率下精准捕捉海冰边缘的细微光学梯度变化。检测头在进行目标分类和边界框回归时, 可同时利用浅层 Sobel 模块提供的精确边缘信息和深层卷积特征提供的强语义信息, 二者形成边缘定位和语义识别协同的互补机制: 浅层边缘梯度特征为边界框回归提供了明确的位置约束, 缓解低对比度下目标边界模糊导致的回归漂移; 深层语义特征则确保目标不会被误判为背景。这一设计与仅依靠深层特征进行边界回归的原始 YOLOv7 相比, 在定位精度上具有明确优势。

3.2 Sobel 边缘卷积模块 workflow

在 Sobel 轮廓提取模块嵌入浅层 ELAN 模块中, 遵循特征输入—分向梯度提取—梯度融合—边缘输出的处理流程。输入特征图经水平 Sobel 卷积核和垂直 Sobel 卷积核分别进行卷积运算, 水平核通过计算像素水平方向的灰度差值提取海冰的垂直边缘特征, 垂直核通过计算垂直方向的灰度差值提取海冰的水平边缘特征。提取到的水平与垂直梯度特征图经自适应加权融合后, 输出边缘增强特征图。模块工作数据流如图 3 所示。




图 3 Sobel 算子工作流程

Fig. 3 Operating Flow of the Sobel Operator

具体而言, 本文采用可训练的自适应权重参数, 通过网络端到端训练自动学习水平与垂直方向梯度的最优融合比例。设水平方向边缘特征为 E_x , 垂直方向边缘特征为 E_y , 水平和垂直方向的自适应融合权重分别为 α 和 β , 则融合后的边缘特征为 $X_s = \alpha \cdot E_x + \beta \cdot E_y$, 其中 X_s 为融合后的边缘特征, α 和 β 为可学习参数, 其初始值随机预设, 在训练过程中根据损失函数自动调整。相比固定加权(如等权叠加或梯度模值计算), 自适应加权能够根据不同方向的海冰边缘特征自动调整融合策略: 对于水平冰脊轮廓等主要反映在垂直梯度上的特征, 网络可自动增大 β 权重; 对于垂直冰缝等主要反映在水平梯度上的特征, 网络可自动增大 α 权重。

该特征图显著放大了海冰与海水背景之间的光学对比度边界, 使海冰目标的轮廓清晰可辨, 为后续检测提供关键的光学结构线索。单独经过边缘提取算子的可视化结果如图 4 所示。




图 4 单独经过 Sobel 卷积后的效果示意

Fig. 4 Effect Diagram of Standalone Sobel Convolution

针对 Sobel 算子对噪声敏感的共性问题, 本文通过双重机制提升其在低对比度红外海冰场景下的鲁棒性。首先, 红外海冰图像中的噪声主要表现为高斯噪声, 且在海面红外图像中常表现为孤立噪声点^[17], 而真实海冰边缘具有空间连续性——边缘像素的梯度方向沿目标轮廓呈一致性分布, 相邻像素间存在强空间关联。Sobel 算子通

过计算 3×3 邻域内的灰度梯度,能够利用这种空间连续性区分孤立噪声点与连续边缘。其次, Sobel 模块作用于 ELAN 模块输出的浅层卷积特征,而非原始红外图像,卷积操作本身对高频噪声具有平滑抑制效果,特征通道中的噪声分量经过多层卷积和激活函数处理后已大幅衰减。由表 6 的消融实验结果可知,单独引入 Sobel 边缘增强分支后,浓雾场景下检测精确率达 0.999,未出现伪边缘导致的误检上升,验证了该模块在本任务场景下的抗噪可靠性。

3.3 LKC 大核卷积工作流

LKC 大核卷积模块经过设计,嵌入在深层 ELAN 模块中,使用双分支大核卷积及互补特征融合的办法来对全局上下文和局部细节进行并行提取:

Step 1: 双分支并行特征提取。设计两条互补的特征提取分支。主分支采用卷积降维—大核卷积—卷积升维的瓶颈式结构:首先通过 1×1 卷积将输入特征通道数压缩至原来的 $1/r$,表示在保留核心语义信息的前提下大幅减少后续大核卷积的计算量,其中 r 为通道压缩倍率,用于控制瓶颈结构的降维比例;随后使用可配置尺寸的大核卷积进行特征提取,解决低对比度下海冰与海水边界模糊、全局特征辨识度低的问题;最后通过 1×1 卷积恢复通道维度。短接分支采用标准 3×3 卷积,专注于提取海冰的局部边缘与纹理细节,弥补大核卷积在精细特征表征上的不足,与主分支的全局特征形成有效互补。

Step 2: 跨分支特征拼接与融合。将主分支与短接分支输出的特征图在通道维度进行拼接,整合全局上下文与局部细节的互补特征;随后通过 1×1 卷积对拼接后的高维特征进行维度变换,消除不同分支特征间的冗余与干扰,强化特征的判别性。

Step 3: 激活与全局特征输出。融合后的特征图经过 ReLU 激活函数引入非线性变换,最终输出同时包含海冰整体形态特征与精细边缘特征的多尺度全局特征图。

大核卷积在扩展感受野、获取全局上下文信息的同时,存在引入冗余背景信息的共性风险。本文从三个层面抑制该负面影响。第一,部署位置约束: LKC 模块嵌入深层 ELAN 模块,特征经多次卷积抽象后,低层纹理噪声与无关背景已被逐层过滤,大核卷积在此层引入的无效背景干扰显著降低。第二,双分支结构互补:如图 2 所示,短接分支保留标准 3×3 卷积,感受野较小,专注于海冰目标的局部纹理特征,其输出不受远处无关背景干扰。第三,通道特征筛选:跨分支拼接后的 1×1 卷积在通道维度实现自适应加权,训练过程中自动向抑制大核分支中与目标语义无关的背景通道方向优化权重,保留有效上下文信息。由表 7 可知,单独引入 LKC 模块时浓雾场景精确率为 0.812,存在一定误检风险;与 Sobel 边缘分支协同后,精确率提升至 0.967,表明双分支互补结构可有效抵抗全局背景干扰,充分发挥大核卷积的上下文建模优势。




图 5 Sobel 算子和 LKC 模块在 ELAN 模块中的嵌入位置

Fig. 5 Embedding Positions of the Sobel Operator and LKC Module in the ELAN Module

4 实验与结果分析

4.1 数据集与实验设置

实验采用多气象多场景红外海冰数据集, 由于目前相关数据集稀缺, 研究中构建了红外海冰多气象数据集, 共含近 2000 张红外图像, 分辨率统一为 1200×750 , 涵盖晴天、轻雾和浓雾等典型光学环境, 目标类别包括浮冰、平整冰和冰脊三类。由于目标种类分布极不均匀, 浮冰种类占据绝大部分, 因此评估时选择浮冰目标作为评估目标。数据集按 8:1:1 的比例划分为训练集、验证集与测试集, 训练阶段采用随机水平翻转、随机亮度调整和随机高斯噪声添加等数据增强策略, 以模拟不同光照和噪声干扰下的红外成像效果。数据集中部分图像如图 6 所示。其每行为不同气象场景。自上到下每行的气象分别为晴、轻雾、浓雾、雪、雨。




图 6 数据集中不同气象的图像示例

Fig. 6 Image Samples Under Different Weather Conditions in the Dataset

注: (a):晴天 (b):轻雾 (c):浓雾 (d):雪天 (e):雨天

实验以原始 YOLOv7 为基线模型, 在其基础上构建了仅加 Sobel 模块、仅加 LKC 模块和双模

块融合三组对照模型。训练参数统一配置: 批次大小为 16, 输入图像归一化至 640×640 像素, 训练总轮数为 300 轮。硬件环境为 NVIDIA GeForce RTX 4090 显卡, 24GB 显存。

结合实际与项目需求, 选取四项关键指标量化模型性能: (1)精确率 P(Precision): 反映模型检测结果中真阳性海冰目标占有检测目标的比例, 衡量误检率(如将海面反光误判为薄冰)的控制能力; (2)召回率 R(Recall): 反映模型正确检测的海冰目标占有真实目标的比例, 衡量低对比度碎冰、薄冰等易漏检目标的识别能力, 结合课题要求, 此指标为重点关注指标; (3)mAP@0.5 (mean Average Precision, mAP): 交并比 IoU(Intersection over Union) 阈值为 0.5 时的平均精度, 综合评估海冰目标的检测精度; (4)计算量 Comput. (Computational cost): 反映模型的推理计算量, 验证模块引入对计算效率和模型实时性的影响。其中召回率作为重点关注指标, 反映模型对低对比度碎冰、薄冰等易漏检目标的全面检出能力。

4.2 对比实验结果

本节实验的目标是检验 Sobel 边缘提取模块及 LKC 模块配合使用的效果, 明确二者结合后对复杂气象条件下目标检测模型的性能增益, 同时定量分析改进方案对计算开销的影响。

实验测试集完全覆盖全混合气象场景 All、晴天场景 Clear、轻雾场景 Fog2、浓雾场景 Fog5 四类典型工况, 结合上一小节所讨论的诸种评价指标来对比基线模型与改进模型的性能差异。实验测试结果如表 1、表 2 所示, 检测图实例如图 7, 可以看出, 改进网络相比原始网络, 对目标漏检、误检都有有效抑制, 且所检出的目标置信度更高。

实验结果显示, 雾天场景下的检测指标优于晴天场景, 其原因可以从红外成像的物理特性出发进行分析, 轻雾遮挡了太阳的直射辐射, 同时掩盖了部分不利于检测的噪声, 画面更为纯净, 同时轻雾状况下图像的对比度降低还没有到严重影响检测性能的程度。

从实验设计的严谨性出发, 要保证实验的单一变量控制原则, 仅 Fog2 与 Fog5 两组场景具备严谨的对比条件: 二者除雾浓度梯度存在差异外, 数据集的目标类型、热辐射环境、背景干扰特征、

标注规则以及图像数量均完全一致,可精准剥离雾浓度对模型检测性能的影响。而晴天与雾天场景之间,存在太阳辐射强度、海冰-海水热对比度、海面背景噪声,以及数据集本身图像数量等多个变量差异,无法单独验证模型的抗雾性能,不具备单一变量对比的严谨性。

表 1 混合气象以及晴天测试集测试结果

Tab. 1 Test Results on Mixed Weather and Sunny Test Sets

Weather		All			Clear		
Model	Comput.	P	R	mAP@0.5	P	R	mAP@0.5
Baseline	103.2	0.788	0.551	0.558	0.971	0.439	0.497
Baseline+Sobel+LKC	103.5	0.830	0.630	0.627	0.864	0.507	0.533

表 2 轻雾及浓雾测试集测试结果

Tab. 2 Test Results on Light Fog and Dense Fog Test Sets

Weather		Fog2			Fog5		
Model	Comput.	P	R	mAP@0.5	P	R	mAP@0.5
Baseline	103.2	0.928	0.605	0.618	0.893	0.581	0.594
Baseline+Sobel+LKC	103.5	0.886	0.721	0.705	0.967	0.674	0.671




图 7 基线网络和改进网络的检测结果

Fig. 7 Detection Result Comparison Between the Baseline Network and the Improved Network

注: 第一行为基线网络检测结果, 第二行为改进网络结果

核心数据分析如下: 在全混合气象测试集上, 改进模型较基线模型实现了全面的性能提升: 精确率 P 从 0.788 提升至 0.83, 增长 4.2%; 核心指标召回率 R 从 0.551 提升至 0.63, 增长 7.9%; mAP@0.5 从 0.558 提升至 0.627, 绝对涨幅达 6.9%。该结果验证了 Sobel 与 LKC 模块的协同效应, 可同时优化模型的检测精度与目标检出能力, 大幅缓解基线模型漏检率偏高的问题。

在晴天测试集上, 基线模型呈现出高精确率、低召回率的失衡特性, 其精确率 P 达 0.971, 但召回率 R 仅为 0.439, 存在目标漏检问题。改进后, 模型召回率 R 提升至 0.507, 绝对涨幅 6.8%, 相对涨幅超 15%; 尽管精确率 P 有小幅回落, 但最终 mAP@0.5 从 0.497 提升至 0.533, 绝对涨幅 3.6 个百分点。这表明 Sobel 与 LKC 模块的协同作用, 有效平衡了模型的精确率与召回率, 减少了基线模型在晴天场景下的漏检, 实现了整体检测性能的优化。

雾天场景下, 大气散射会导致图像边缘模糊、特征退化, 是目标检测的典型难点场景, 也是本次实验验证模块协同能力的核心工况。在轻雾 Fog2 测试集上, 改进模型召回率 R 从 0.605 大幅提升至 0.721, 绝对涨幅 11.6%, 相对涨幅超 19%; mAP@0.5 从 0.618 提升至 0.705, 绝对涨幅达 8.7%, 是测试集中涨幅最高的工况。在浓雾 Fog5 测试集上, 改进模型实现了精确率与召回率的同步提升: 精确率 P 从 0.893 提升至 0.967; 召回率 R 从 0.581 提升至 0.674, 提升 9.3 个百分点; mAP@0.5 绝对涨幅 7.7%, 相对涨幅超 13%。

本节实验通过多场景对比测试, 完成了增强模块的协同性能验证, 确认 Sobel 边缘提取模块与 LKC 模块具备优异的协同互补效应, 在仅带来可忽略计算量增长的前提下, 可全面提升模型在全混合气象、晴天、轻雾、浓雾四类场景下的目标检测精度, 尤其对雾天等恶劣气象场景的性能提升效果最为突出, 核心指标 mAP@0.5 最高涨幅达 8.7 个百分点。其次, 改进方案有效解决了基线模型存在的召回率偏低、漏检严重、精确率与召回率失衡的问题, 在各类场景下均显著提升了模型的目标召回能力, 在浓雾场景下更是实现了精确率与召回率的同步提升, 大幅优化了模型的泛化能力与鲁棒性。同时, 改进方法未破坏模型的轻量化特性, 保持了良好的实时推理能力, 适配实时检测等实际工程场景的部署需求, 充分验证了模块协同应用的有效性与工程可行性。

4.3 与其他算法的检测效果对比

为进一步验证所提方法的优势, 本文选择将改进后的网络与 YOLOv5、YOLOv8、YOLOv11 等主流单阶段检测器进行了对比实验。所有模型均采用官方预训练权重进行微调, 训练配置与本

文基线保持一致, 在相同的全混合气象测试集 (All) 上评估, 结果如表 3 所示。

表 3 不同 YOLO 系列检测器在混合气象测试集 (All) 上的检测指标对比

Tab. 3 Comparison of Detection Metrics for Different YOLO-Series Detectors on the Mixed-Weather Test Set

Model	P	R	mAP@0.5
YOLOv5	0.808	0.545	0.636
YOLOv8	0.838	0.623	0.701
YOLOv11	0.776	0.584	0.652
YOLOv7(Baseline)	0.788	0.551	0.558
Ours	0.830	0.630	0.627

从测试数据中可以看出, YOLOv5、YOLOv8、YOLOv11 作为通用目标检测器, 未做针对性场景优化, 可取得一定的基础性能且整体性能处于相近水平。其 mAP@0.5 分布在 0.636~0.701 区间, 召回率分布在 0.545~0.623 区间。三者均未针对低对比度红外场景设计专用特征增强模块, 在浓雾等恶劣气象条件下, 通用检测器仅依靠自身特征提取能力难以有效应对边缘模糊和全局语义缺失的双重退化, 目标召回能力存在共性短板。

本文通过 Sobel 算子与 LKC 模块的分层协同设计, 在 YOLOv7 基础上针对性强化了边缘光学梯度特征和全局上下文建模能力。鉴于海冰监测需实现危险目标的尽数检出, 召回率为任务核心评价指标, 本文方法在全混合气象测试集上召回率达 0.630, 显著优于上述通用检测器。此外, Sobel 模块的梯度提取与自适应融合机制仅依赖特征图的灰度梯度信息, LKC 模块的双分支瓶颈式结构仅依赖特征图的尺寸和通道数, 二者的设计均不依赖于特定 YOLO 版本, 理论上可直接迁移至其他 YOLO 系列架构中, 具有良好的方法普适性。

4.4 消融实验

为验证所引入的 Sobel 边缘增强模块与 LKC 大核卷积模块对检测性能的独立贡献及协同增效作用, 本节设计消融实验, 定量分析各模块在边缘特征强化、全局上下文捕捉、低对比度目标检测精度与实时性等维度的提升效果, 确保实

验结果能够精准反映目标模块的核心特性, 同时排除无关因素干扰, 验证所提模块适配海冰检测场景的有效性。

消融实验以原始 YOLOv7 为基准模型, 通过引入单一模块控制变量, 构建 4 组对比模型, 所有模型采用完全一致的训练配置与评估体系, 保证对比的公平性与结果的可信度:

(1) 基准模型 (Baseline): 未引入任何改进模块的原始 YOLOv7, 主干网络保留 4 个原生 ELAN 结构; (2) 仅加 Sobel 模块 (YOLOv7+So-bel): 在第 2 个 ELAN 结构中嵌入自适应加权 Sobel 梯度融合分支, 该分支加入到 ELAN 原有卷积的分支中, 针对性强化低对比度海冰的边缘轮廓; (3) 仅加 LKC 模块 (YOLOv7+LKC): 在第 4 个 ELAN 结构中嵌入 LKC, 扩大感受野以捕捉全局上下文特征; (4) 双模块融合 (YOLOv7+So-bel+LKC): 同时引入上述两个模块, 验证 Sobel 模块的局部边缘特征与 LKC 模块的全局上下文特征是否存在协同增效作用, 重点评估低对比度场景下的性能增益。实验结果如表 4、表 5、表 6、表 7 所示, 变化趋势如图 8 所示。

表 4 单一模块在混合场景下的测试数据

Tab. 4 Performance of Individual Modules on the Mixed-Weather Test Set

Weather		All			
Model	Comput.	P	R	mAP@0.5	
Baseline	103.2	0.788	0.551	0.558	
Baseline+Sobel	103.2	0.834	0.601	0.592	
Baseline+LKC	103.5	0.770	0.568	0.565	
Baseline+Sobel+LKC	103.5	0.830	0.630	0.627	

表 5 单一模块在晴天场景下的测试数据

Tab. 5 Performance of Individual Modules on the Clear Weather Test Set

Weather		Clear			
Model	Comput.	P	R	mAP@0.5	
Baseline	103.2	0.971	0.439	0.497	
Baseline+Sobel	103.2	0.818	0.480	0.532	
Baseline+LKC	103.5	0.921	0.451	0.510	
Baseline+Sobel+LKC	103.5	0.864	0.507	0.533	

表 6 单一模块在轻雾场景下的测试数据

Tab. 6 Performance of Individual Modules on the Light Fog Test Set

Weather		Fog2		
Model	Comput.	P	R	mAP@0.5
Baseline	103.2	0.928	0.605	0.618
Baseline+Sobel	103.2	0.879	0.674	0.641
Baseline+LKC	103.5	0.951	0.605	0.646
Baseline+Sobel+LKC	103.5	0.886	0.721	0.705

表 7 单一模块在浓雾场景下的测试数据

Tab. 7 Performance of Individual Modules on the Dense Fog Test Set

Weather		Fog5		
Model	Comput.	P	R	mAP@0.5
Baseline	103.2	0.893	0.581	0.594
Baseline+Sobel	103.2	0.999	0.628	0.631
Baseline+LKC	103.5	0.812	0.605	0.600
Baseline+Sobel+LKC	103.5	0.967	0.674	0.671

Sobel 模块是低对比度海冰检测性能提升的重要贡献项,在所有场景下均实现了检测性能的显著提升,且无明显额外计算开销,计算量几乎与基线模型完全一致。在混合气象场景下,相较基线模型,召回率 R 从 0.551 提升至 0.601, mAP@0.5 从 0.558 提升至 0.592,增幅 6.1%,精准解决了低对比度海冰边缘模糊、与背景边界辨识度低的核心痛点。雾天场景下,模块增益随气象恶劣程度提升愈发显著。中轻雾 Fog2 场景下,召回率 R 从 0.605 提升至 0.674,增幅 11.4%;浓雾 Fog5 场景下,召回率从 0.581 提升至 0.628,增幅 8.1%, mAP@0.5 从 0.594 提升至 0.631,增幅 6.2%。即使在强退化场景中,仍能通过边缘梯度提取强化海冰目标的边界特征,有效降低漏检率。晴天场景下相较基线模型,召回率增幅 9.3%, mAP@0.5 增幅 7.0%,提升至 0.532,对晴天下的低对比度浮冰小目标检测效果优化显著。

LKC 模块的独立增益相对温和,核心价值体现在全局上下文信息的补充,且仅使计算量从 103.2 GFLOPs(Giga Floating-point Operations)微增至 103.5 GFLOPs,计算开销增幅可忽略不计。混合气象情况下,相较基线模型 mAP@0.5 从

0.558 提升至 0.565,召回率从 0.551 提升至 0.568,增幅 3.1%,对整体性能的提升幅度弱于 Sobel 模块,说明全局上下文增强的增益,不及边缘特征强化对低对比度目标的直接作用。而雾天退化场景中,轻雾 Fog2 场景下, mAP@0.5 从 0.618 提升至 0.646,增幅 4.5%;浓雾 Fog5 场景下,召回率 R 从 0.581 提升至 0.605,通过扩大感受野捕捉远距离小目标的全局语义,对雾天场景下的误检率控制有正向作用。




图 8 消融实验召回率指标趋势图

Fig. 8 Recall Trend Curve for Ablation Experiments

从特征退化的本质来看,低对比度红外海冰图像同时存在两种不同性质的特征损失:一是边缘梯度退化,由浓雾遮挡太阳直射辐射后海冰与海水热辐射差异被压缩所致,表现为目标边界模糊、与背景难以区分;二是全局语义缺失,由远距离小目标成像像素极少、感受野受限所致,表现为局部特征无法有效关联周边背景信息。Sobel 模块通过强化水平与垂直方向的光学梯度变化,改善特征图边缘梯度退化问题;LKC 模块通过扩大感受野将高层特征图局部光学斑块与周围海水的全局辐射背景进行关联建模,并由模型自适应学习目标的响应区域,弥补全局语义缺失问题。二者针对不同类型的特征缺陷进行互补性增强,因此协同使用时性能显著优于各自单独使用。消融实验中双模块融合在浓雾场景下召回率达 0.674、mAP@0.5 达 0.671,分别比单独使用 Sobel 模块高出 4.6 个和 4.0 个百分点,比单独使用 LKC 模块高出 6.9 个和 7.1 个百分点,充分印证了上述互补机制的有效性。

上述结果表明, Sobel 模块强化边缘特征、LKC 模块补充全局语义,二者形成良好的互补协同关系,实现了 1+1>2 的性能提升。尤其在浓雾等极端恶劣气象场景中,双模块融合的增益幅度超越单模块,充分验证了边缘-全局协同增强设计

的合理性与有效性。

4.5 局限性分析

本文针对低对比度红外海冰检测任务, 提出边缘-全局协同增强的检测方法, 在浓雾等恶劣气象条件下取得了显著的性能提升。为明确方法的适用边界, 现将其局限性与未来改进方向讨论如下。

第一, Sobel 边缘增强模块的性能依赖输入特征的噪声水平。本文将该模块部署于浅层卷积特征之后, 依托卷积操作的天然平滑作用实现了良好的抗噪效果, 但在原始图像噪声极强的极端场景(如暴雪、强电磁干扰)下, 浅层卷积的滤波能力可能不足, 后续可引入专用去噪预处理或鲁棒性更强的边缘提取算子进一步优化。第二, LKC 大核卷积模块的效果与部署位置(如网络深度或拓扑结构)强相关。本文将其置于网络深层, 且放置于 ELAN 主干路的特殊位置, 依托深层特征的语义抽象性降低了背景干扰; 若部署于浅层, 经实验验证, 大感受野引入的背景噪声会抵消全局建模的增益, 造成检测指标的下降。因此该模块的部署位置需根据任务特性与网络结构谨慎选择并加以充分的实验验证。第三, 方法的跨架构迁移性有待进一步验证。本文 Sobel 与 LKC 模块的核心机制不依赖特定检测框架, 理论上可迁移至其他 YOLO 系列模型, 但其在不同骨干网络下的适配性与性能增益仍需后续实验验证。

参考文献:

- [1] 李明慧. 基于深度学习的 SAR 影像海冰分类研究[D]. 上海: 上海海洋大学, 2019.
LI M H. *Sea ice classification based on deep learning with SAR imagery*[D]. Shanghai: Shanghai Ocean University, 2019. (in Chinese).
- [2] BIJELIC M, GRUBER T, MANNAN F, *et al.*. Seeing through fog without seeing fog: deep multimodal sensor fusion in unseen adverse weather[C]. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, IEEE, 2020: 11679-11689.
- [3] 陈志昆, 魏立新, 李志强, 等. 2017 年夏季北冰洋浮冰区海雾特征分析[J]. 海洋预报, 2019, 36(2): 77-87.
CHEN ZH K, WEI L X, LI ZH Q, *et al.*. Sea fog characteristics over the Arctic pack ice in summer 2017[J]. *Marine Forecasts*, 2019, 36(2): 77-87. (in Chinese).
- [4] WANG CH X, WU H J, JIN ZH. FourLLIE: boosting low-light image enhancement by Fourier frequency information[C]. *Proceedings of the 31st ACM International Conference on Multimedia*, Association for Computing Machinery, 2023: 7459-7469.
- [5] KIM Y T. Contrast enhancement using brightness preserving bi-histogram equalization[J]. *IEEE Transactions on Consumer Electronics*, 1997, 43(1): 1-8.
- [6] Ancuti C, Ancuti C O, Haber T, *et al.*. Enhancing underwater images and videos by fusion[C]. *Proceedings of the 2012 IEEE Conference on Computer Vision and Pattern Recognition*, IEEE, 2012: 81-88.

最后, 本文实验基于现有船载红外海冰数据集开展, 后续将在更多极地海域的实测走航数据上验证方法的泛化能力, 拓展其工程应用范围。


5 结 论

本文针对红外海冰图像中目标与背景灰度差异微弱、边缘轮廓模糊的低对比度检测难题, 提出了一种面向低对比度红外海冰图像的边缘-全局协同增强检测方法。通过在检测网络浅层嵌入 Sobel 轮廓提取模块, 强化海冰边缘的法向与切向光学梯度特征; 在深层引入 LKC 大核卷积模块, 以双分支瓶颈式结构在扩大感受野的同时保留精细边缘特征, 将局部光学斑块与全局辐射背景进行关联建模, 弥补小目标光学特征稀疏的缺陷。实验结果表明, 所提方法在浓雾条件下的极低对比度场景中, 召回率达 0.674, mAP@0.5 达 0.671, 较基线模型分别提升 9.3 个百分点和 7.7 个百分点。消融实验验证了边缘增强与全局建模两模块的独立贡献与协同增效作用。所提方法在保持轻量化特性的同时, 显著提升了低光学对比度海冰目标的检测精度与鲁棒性, 为恶劣气象下红外海冰检测提供了一个有效的改进技术方案。该方法可直接部署于船载红外监测系统, 为极地航行安全和海洋环境监测提供技术支撑。

- [7] REN X Y, JIAO B Y, PENG ZH M, *et al.*. MSFFNet: a multilevel sparse feature fusion network for infrared dim small target detection[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2025, 18: 147-159.
- [8] 蔚婧, 张磊, 丁美琪, 等. 空频域特征融合的红外弱小目标检测网络[J]. 西安电子科技大学学报, 2025, 52(6): 32-44. YU J, ZHANG L, DING M Q, *et al.*. Infrared dim and small target detection network with spatial-frequency feature fusion[J]. *Journal of Xidian University*, 2025, 52(6): 32-44. (in Chinese).
- [9] 王伯霄, 宋延嵩, 董小娜. 难点注意力感知红外小目标检测网络[J]. 中国光学 (中英文), 2024, 17(3): 538-547. WANG B X, SONG Y S, DONG X N. Indistinguishable points attention-aware network for infrared small object detection[J]. *Chinese Optics*, 2024, 17(3): 538-547. (in Chinese).
- [10] 周卓, 檀帅兵, 白昆, 等. 多尺度空间与形态学特征的红外小目标检测方法[J]. 弹箭与制导学报, 2026, 46(3): 291-304. ZHOU ZH, TAN SH B, BAI K, *et al.*. Infrared small target detection based on multi-scale spatial loss and morphological features[J]. *Journal of Projectiles, Rockets, Missiles and Guidance*, 2026, 46(3): 291-304. (in Chinese).
- [11] 陈科, 蒋行国, 林国军, 等. 红外小目标检测的轻量级 ERM-DETR 算法[J]. 激光与红外, 2025, 55(12): 1950-1957. CHEN K, JIANG X G, LIN G J, *et al.*. Lightweight ERM-DETR algorithm for infrared small target detection[J]. *Laser & Infrared*, 2025, 55(12): 1950-1957. (in Chinese).
- [12] 赵佳乐, 姜树理, 林超. 多光谱融合的红外舰船目标轻量化检测[J]. 光学精密工程, 2025, 33(8): 1327-1338. ZHAO J L, LOU SH L, LIN CH. A lightweight detection of multi-spectral infrared ship target[J]. *Optics and Precision Engineering*, 2025, 33(8): 1327-1338. (in Chinese).
- [13] TANG Y, XU T F, QIN H L, *et al.*. IRSTD-YOLO: an improved YOLO framework for infrared small target detection[J]. *IEEE Geoscience and Remote Sensing Letters*, 2025, 22: 7001405.
- [14] 薛驰, 陈小梅, 李海彤. 融合背景估计与相对局部对比度的天基短波红外弱小目标检测[J]. 光学精密工程, 2026, 34(3): 450-465. XUE CH, CHEN X M, LI H T. SWIR weak targets detection on space-based platform integrating background estimation and relative local contrast[J]. *Optics and Precision Engineering*, 2026, 34(3): 450-465. (in Chinese).
- [15] 赵阳, 杨文贵, 高翠云. 基于全局双组注意力的红外与可见光图像融合[J]. 液晶与显示, 2025, 40(12): 1840-1852. ZHAO Y, YANG W G, GAO C Y. Infrared and visible image fusion based on global dual-group attention[J]. *Chinese Journal of Liquid Crystals and Displays*, 2025, 40(12): 1840-1852. (in Chinese).
- [16] CHEN Y SH, WANG B R, GUO X Y, *et al.*. DEYOLO: dual-feature-enhancement YOLO for cross-modality object detection[C]. *27th International Conference on Pattern Recognition*, Springer, 2024: 236-252.
- [17] 刘杰, 安博文. 海面红外小目标检测算法研究[J]. 红外技术, 2015, 37(1): 16-19. LIU J, AN B W. Research on the detection algorithm for infrared small target on the sea[J]. *Infrared Technology*, 2015, 37(1): 16-19. (in Chinese).

作者简介:

杜浩铖 (2001—), 男, 河北邯郸人, 硕士研究生, 主要从事机器视觉、图像处理及目标检测方面的研究。E-mail: duhaocheng163@163.com



陶淑苹 (1986—), 女, 山东潍坊人, 博士, 研究员, 博士生导师, 主要从事光学遥感、计算成像、遥感图像处理方面的研究。E-mail: taoshuping11@sina.com