

光学遥感图像显著目标检测的边缘增强轻量化模型探究

全彬彬

广东工业大学数学与统计学院, 广东 广州

收稿日期: 2026年3月2日; 录用日期: 2026年3月26日; 发布日期: 2026年4月7日

摘要

光学遥感图像(ORSI)场景复杂且目标尺度多变, 现有显著目标检测(SOD)模型存在参数量大、计算成本高或边缘信息利用不足导致目标边缘模糊等问题。针对上述缺陷, 提出一种边缘引导的轻量化注意力网络模型(EGLANet), 实现光学遥感图像显著目标的高精度、轻量化检测。该模型以MobileNet V3为骨干网络生成五级初级特征图, 先通过由跨层相关性模块(CLC)和多尺度并行卷积构成的边缘多尺度注意力模块(EMSAM)提取四级边缘特征图与精细边缘图, 再利用CLC、融合 $1 \times k/k \times 1$ 分组卷积的多尺度注意力模块(MSAM)结合边缘引导模块(EGM), 将边缘信息融入目标检测过程以精准定位显著目标; 损失函数采用二值交叉熵(BCE)与交并比(IoU)损失的组合形式, 同时约束边缘提取与目标检测任务。在公开光学遥感图像显著目标检测数据集EORSSD上开展对比实验, 选取10种先进模型作为对比对象, 从定性与定量角度验证模型性能。实验结果表明, EGLANet实现了参数量仅为1.75 M, 显著目标检测效果却优于其它模型, 在保证检测精度的同时提升计算效率, 为光学遥感图像显著目标检测提供了一种高效的轻量化解决方案。

关键词

光学遥感图像, 显著目标检测, 边缘增强, 轻量化网络

Exploration of a Lightweight Model for Edge Enhancement for Salient Object Detection in Optical Remote Sensing Images

Binbin Quan

School of Mathematics and Statistics, Guangdong University of Technology, Guangzhou Guangdong

Received: March 2, 2026; accepted: March 26, 2026; published: April 7, 2026

Abstract

Optical Remote Sensing Images (ORSI) feature complex scenes and variable target scales. Existing Salient Object Detection (SOD) models suffer from issues such as large parameter count, high computational cost, or insufficient utilization of edge information, leading to blurred target edges. To address these shortcomings, we propose an Edge-Guided Lightweight Attention Network (EGLANet) to achieve high-precision and lightweight detection of salient objects in optical remote sensing images. This model utilizes MobileNet V3 as the backbone network to generate five-level primary feature maps. It first extracts four-level edge feature maps and fine edge maps through an Edge Multi-Scale Attention Module (EMSAM) composed of a Cross-Layer Correlation (CLC) module and multi-scale parallel convolution. Then, it integrates edge information into the target detection process using a combination of CLC, a multi-scale attention module (MSAM) that fuses $1 \times k/k \times 1$ grouped convolution, and an Edge Guidance Module (EGM) to accurately locate salient objects. The loss function combines Binary Cross Entropy (BCE) and Intersection over Union (IoU) losses, simultaneously constraining edge extraction and target detection tasks. Comparative experiments were conducted on the public optical remote sensing image salient object detection dataset EORSSD, selecting 10 advanced models as benchmarks to verify the model performance from both qualitative and quantitative perspectives. The experimental results show that EGLANet achieves superior salient object detection performance with only 1.75 M parameters, improving computational efficiency while maintaining detection accuracy, providing an efficient and lightweight solution for salient object detection in optical remote sensing images.

Keywords

Optical Remote Sensing Images, Salient Object Detection, Edge Enhancement, Lightweight Network

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

显著目标检测(SOD) [1]-[3]是计算机视觉领域中的一项关键技术,可以在图像中精准识别提取出那些视觉上独特的目标或区域,该技术在图像理解[4] [5]、动作识别[6]、目标跟踪[7]-[9]等领域发挥着关键作用,为后续高级视觉任务提供了重要的预处理支持。

显著目标检测任务主要处理的图片分为自然场景图像(NSIs)和光学场景图像(ORSIs),前者主要通过手持相机获得,后者主要通过卫星与航空传感器获得,两者都具有红绿蓝三个光学波段,但是后者的场景往往更加复杂多样,所以对技术方面要求更高。但 ORSI-SOD 具有重要的现实意义,它能够帮助我们在军事侦察中快速地发现 and 识别图像中的关键目标,为农业生产提供精准的土地利用和作物监测信息,以及在救灾过程中及时发现受灾区域和救援目标等。

鉴于光学遥感图像显著目标检测具有重要的理论意义和实际应用价值,相关模型研究不断推进,涌现出多种代表性方法:Liu 等人[10]提出 US-CMC 模型,基于颜色马尔可夫链与圆形特征相关性理论实现对油库的无监督显著检测。Li 等人[11]提出 LVNet 模型,设计 L 型双流金字塔模块与 V 型嵌套编码-解码结构,通过双流金字塔提取多尺度互补特征以感知目标局部细节,借助嵌套连接融合编解码特征,实现复杂背景高效抑制。Zhang 等人[12]提出 DAFNet,引入含全局特征聚合单元与级联金字塔注意力单元的 GCA 模块,前者增强空间位置特征嵌入关联性,后者将注意力图从粗到精优化,可捕获长距离语义关

联、适配遥感目标尺度变化，并引导高维特征注意力图生成。Zhou 等人[13]提出 ERPNet，采用编码器 - 双并行解码器结构，边缘提取模块与编码器构成 U 型结构以提供精准边缘线索并保障信息完整，特征融合模块通过 EPAU 将边缘信息融入解码，锐化目标定位并校准特征学习方向。Li 等人[14]提出 CorrNet，针对光学遥感图像特性进行轻量化优化，对 VGG-16 主干网络轻量化处理后，通过特征相关性模块(CorrM)挖掘高层语义特征中的目标位置信息，以“粗到精”策略生成显著图，最终模型仅含 4.09 M 参数量，实现了检测精度与效率的良好平衡。Luo 等人[15]提出 SAFINet，该网络以 MobileNet V2 为骨干，融合多尺度注意力融合、注意力反馈特征细化及空间相关模块，通过递归的高分辨率空间注意力反馈实现高低分辨率特征的精准融合，最终模型仅含 3.12 M 参数量，同样实现了检测精度与效率的良好平衡。

这些方法在光学遥感图像显著目标检测任务上均取得了较好的检测性能，但是部分模型参数量过大，计算成本过高；部分模型没有充分利用边缘信息，目标存在边缘模糊等问题。针对这些问题，本文提出一个边缘增强轻量型模型(Edge-Guided Lightweight Attention Network, EGLANet)，该模型主要由三部分组成：第一部分是主干网，以 MobileNet V3 作为主干网，生成五个初级特征图；第二部分是边缘提取模块，利用第一部分的初级特征图获得四个边缘特征图以及一个精细的边缘图；第三部分是目标检测模块，利用第二部分得到的边缘特征图和精细的边缘图来获得最终的显著目标图。经三模块协同处理，输入光学遥感图像即可得到精细的显著目标预测结果。

2. 模型介绍

2.1. 模型框架

图 1 展示了本文模型的主体框架，图片从上往下依次是主干网、边缘提取模块和目标检测模块。

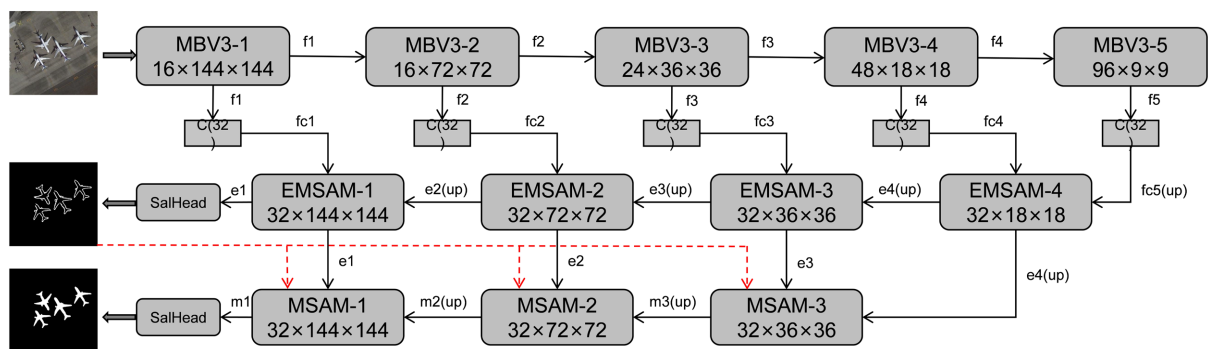


Figure 1. Model framework diagram

图 1. 模型框架图

2.1.1. 主干网

文献[15]提出的 SAFINet 模型选择 MobileNet V2 [16]作为主干网进行编码，按网络阶段将 MobileNet V2 划分为五个部分，输出五级编码特征图，从而为后续解码做准备。本次实验则选择 MobileNet V3 [17]作为主干网，具体操作同模型 SAFINet 一样，也是划分成五个部分来获得五个编码特征图 f_i ($i = 1, 2, 3, 4, 5$)，见图 1 模型主体框架第一行。选择 MobileNet V3 的原因是其作为 MobileNet 系列的升级版，在继承 V2 轻量化核心优势的基础上，通过架构优化、激活函数革新、动态网络设计等创新，在性能、效率、泛化能力等方面实现了显著提升。

2.1.2. 边缘提取模块

由图 1 可知，主干网和边缘提取模块之间还经过了一个 C(32)的操作，该操作将五个初级特征图的通

道数统一调整为 32，其结构由 1×1 、 3×3 和 3×3 卷积块拼接而成，实现特征通道的标准化与维度调整。

边缘提取模块由四个 EMSAM (Edge Multi-Scale Attention Module, 边缘多尺度注意力模块)组成, 该模块主要作用是接受主干网编码的初级特征图, 从后往前依次解码出四个边缘特征图 e_i ($i = 1, 2, 3, 4$)以及一个精细的边缘图 se , 为后续显著目标的精准解码提供边缘线索。

每个 EMSAM 均先利用 CLC 结构处理一个浅层特征 $x_{shallow}$ 和一个深层特征 x_{deep} 得到一个跨层相关特征图; 再通过一个多分支多尺度并行卷积结构(具体细节见图 2), 每条分支依次经过 $k \times k$ 、 1×1 、 $k \times k$ 三个卷积块和相乘相加, 其中第一个卷积块后接着一个 BN 层和一个 ReLU 激活函数, 而后面两个卷积块则不接任何函数, 三条分支的 k 值依次取 3、5 和 7, 从而实现了多尺度捕获更加充分的特征信息; 紧接着将三条分支并联后再进行卷积压缩其通道数为初始值, 最后再与跨层相关特征图相加得到对应的边缘特征图。最后 e_i 经过 Salhead (四个卷积块拼接)输出精细的边缘图 se 。

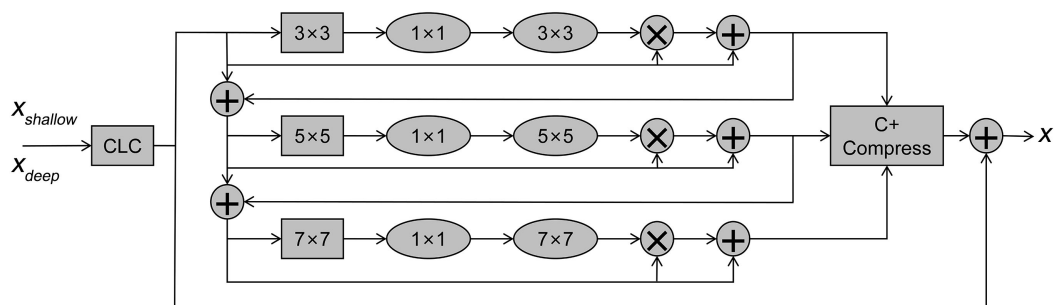


Figure 2. Specific structure of EMSAM
图 2. EMSAM 具体结构

CLC (Cross-Layer Correlation, 跨层相关性)具体结构见图 3, CBAM [18]是经典的轻量级注意力模块, 这里用来处理浅层和深层特征, 再将处理过的特征图拼接在一起, 通过一个卷积后利用函数 Softmax 生成权重图, 再分配对应通道数的权重特征图与初始输入的特征图相乘, 后续再经过并联、卷积和相加即可得到上面提到的跨层相关特征图。




Figure 3. Specific structure of CLC
图 3. CLC 具体结构

2.1.3. 目标检测模块

由图 1 可知, 目标检测模块由三个 MSAM (Multi-Scale Attention Module, 多尺度注意力模块)组成, 该模块主要作用是接受边缘提取模块的四个边缘特征图 e_i ($i = 1, 2, 3, 4$)以及一个精细的边缘图 se , 从后往前进行解码操作, 最终解码出显著目标图 sm 。

MSAM 具体结构如图 4 所示, 与 EMSAM 结构相似, 输入的浅层特征图和深层特征图先经过 CLC

结构处理后再经过一个多分支多尺度并行卷积结构(具体细节见图 4), 该多尺度结构值得注意两个地方: 其一, 采用 $1 \times k$ 与 $k \times 1$ 的分组卷积操作, 在保证多尺度信息提取能力的同时, 大幅减少模型参数量与计算量; 其二, 设置 1×1 conv 操作, 将各分支特征图的通道数压缩至 1。后续操作中分支特征图并联、压缩通道和相加操作与 EMSAM 的一样, 不同的是 MSAM 在输出特征图之前还经过了 EGM (Edge Guidance Module, 边缘引导模块)操作。整个过程产生三个目标特征图 m_i ($i=1, 2, 3$), 最后 m_1 经过 Salhead 输出最终显著目标图 sm 。

EGM 的具体结构见图 5, 该结构主要是利用了边缘提取模块中得到的精细边缘图 se 作为引导, 结合通道注意力(CA)和空间注意力(SA)机制, 对 MSAM 的中间特征图进行加权优化, 突出目标的边缘与区域特征, 抑制背景干扰, 从而获得更精细的目标特征图, 提升显著目标的定位精度与轮廓完整性。对于 EGM 位置的选择, 考虑到经过 CLC 与多尺度卷积输出的特征已具备较完整的目标语义与结构信息。此时引入边缘引导, 能够对已初步成型的目标特征进行精准锐化、边界校准与背景抑制, 引导效果更稳定、更可控。

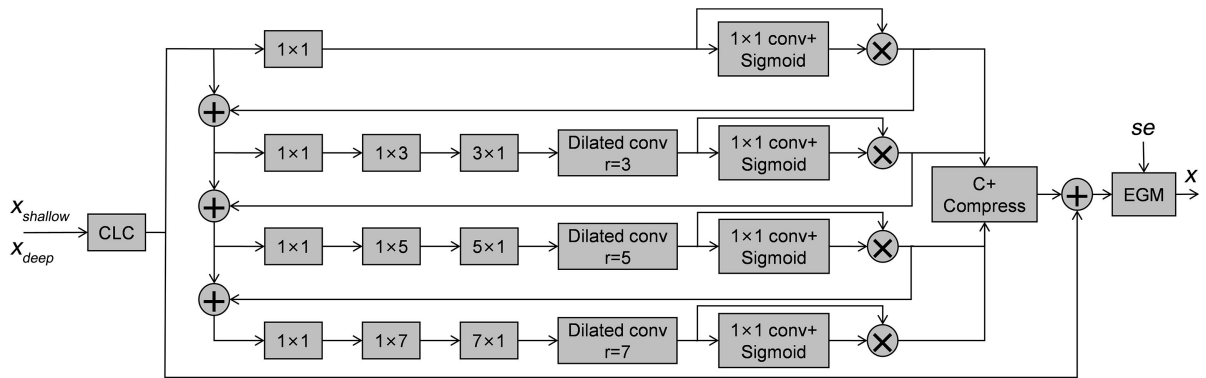


Figure 4. Specific structure of MSAM
图 4. MSAM 具体结构




Figure 5. Specific structure of EGM
图 5. EGM 具体结构

2.2. 损失函数

在文献[14]中, Li 等人使用了经典 BCE 损失和 IoU 损失结合的方法, 该方法综合考虑了不同因素, 能够更好地选出较优模型。并且也有不少前人[19]-[21]使用的损失函数也包括了这两种损失, 已经证明了其可靠性与有效性。因此, 本文参考该方法, 将 BCE 损失与 IoU 损失结合, 分别构建边缘检测损失与目标检测损失, 再通过加权融合得到总损失函数, 公式表示如下:

$$L_{edge} = l_{bce}(se, G_{edge}) + l_{iou}(se_{sig}, G_{edge})$$

$$L_{label} = l_{bce}(sm, G_{label}) + l_{iou}(sm_{sig}, G_{label})$$

$$L_{total} = \alpha L_{label} + (1 - \alpha) L_{edge}$$

其中 se 、 sm 分别为边缘图与显著目标图的原始预测值， se_{sig} 、 sm_{sig} 为经 Sigmoid 激活函数归一化后的预测值； G_{edge} 和 G_{label} 分别为边缘图与显著目标图的真实标签； α 为权重参数，取值范围为 0~1，用于调节调整显著目标图损失和显著边缘图损失的组合比例，实验中我们设置为 0.5。

3. 实验

3.1. 实验数据与实施细节

我们选取了公开基准数据 EORSSD 进行实验，该数据集包含了 2000 张图片(1400 张作为训练集，600 张作为测试集)，涵盖了丰富的遥感场景和目标类型。在数据集预处理阶段，对训练集进行翻转和旋转(90°，180°和 270°)进行数据增强，这样子训练集数量就变成了原来的 8 倍，同时从增强后的训练集中随机抽取 20% 的样本作为验证集，用于训练过程中的模型性能验证与最优模型选取。

本次实验在一台配置为 12th Gen Intel(R) Core(TM) i9-12900 2.40GHz CPU、128-GB RAM 和 NVIDIA RTX A4000 GPU 的机器上实现。在训练阶段，我们把图像尺寸都调整为 288×288 ，训练批次设置为 8，初始学习率为 $1e-4$ ，实验完整迭代 70 轮，学习率衰减率设置为 0.1，每迭代 30 轮对学习率进行一次衰减。

3.2. 实验结果

本次实验选取了 10 种先进的方法进行比较，分别是 VOS [22]、SMFF [23]、CMC [10]、LVNet [11]、DAFNet [12]、ERPNet [13]、CSNet [24]、SAMNet [25]、CorrNet [14]和 SAFINet [15]。为了更好地评估所有模型的性能，先后进行了定性分析和定量分析，定性分析则通过对比所有方法的显著目标图，定量分析则计算了所有模型的 S 测量值(S)、F 测量值(F_β)、交并比(IoU)和平均绝对误差(MAE)四个指标，另外还绘制了其中部分方法的 PR 曲线图和 F 测量值曲线图来进行可视化对比。

3.2.1. 定性分析

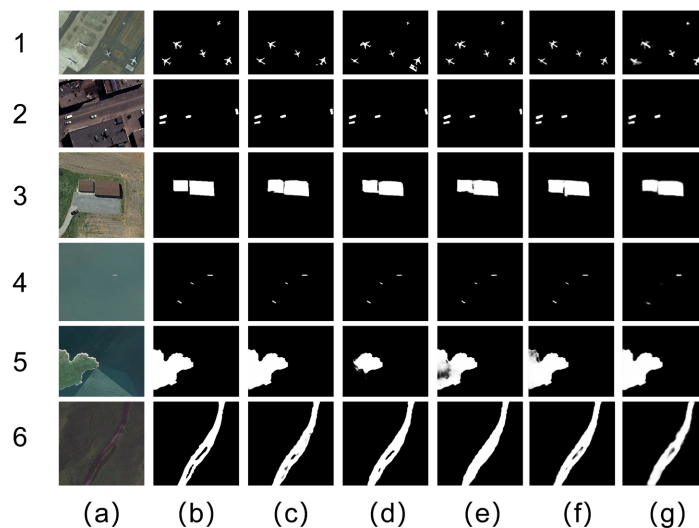


Figure 6. Comparison of significant target prediction maps from different models. (a) Optical remote sensing image; (b) true label; (c) EGLANet; (d) SAFINet; (e) CorrNet; (f) ERPNet-R; (g) DAFNet-R

图 6. 不同模型显著目标预测图的对比。(a) 光学遥感图像；(b) 真实标签；(c) EGLANet；(d) SAFINet；(e) CorrNet；(f) ERPNet-R；(g) DAFNet-R

不同模型显著目标预测图的对比如图 6 所示, 由图可知, 在光学遥感图像显著目标检测任务中, EGLANet 在多类典型场景下展现出优于其它模型的综合性能。由第 1 行、第 2 行和第 4 行这三行图片可知, 在小目标场景中, EGLANet 可精准捕捉稀疏微小目标, 无明显遗漏或误检; 由第 3 行图片可知, 在建筑物等块状目标无直接接触但距离较近的场景中, EGLANet 的边界预测清晰锐利, 与真实标签轮廓高度吻合; 由第 5 行和第 6 行图片可知, 在岛屿和河流等显著目标与背景紧密交错的场景中, EGLANet 预测结果能保持目标连续性与完整性, 并且有效区分了显著区域和非显著区域。综上, 与其他模型相比, EGLANet 在小目标检测能力、目标结构完整性、边界定位精度及复杂背景鲁棒性方面均有显著提升, 检测出的目标轮廓更清晰, 更接近真实标签(GT 图), 对复杂背景的抑制效果更优, 能更完整地检测出显著目标区域。

3.2.2. 定量分析

由表 1 可知, EGLANet 在光学遥感图像显著目标检测任务中, 整体性能显著优于其它对比模型。在 Sm、adpFm、meanFm、maxFm、IoU 等关键评价指标上, EGLANet 分别达到 0.9301、0.8468、0.8666、0.8827、0.8074, 其中 Sm、maxFm、IoU 三项指标为所有模型中的最高值, adpFm (0.8468)、meanFm (0.8666) 略低于 SAFINet 的 0.8575 和 0.8710; 在 MAE 指标上, EGLANet 仅为 0.0061, 仅略高于 DAFNet-R 的 0.0053 和 DAFNet-V 的 0.0060, 显著低于多数对比方法。虽然 EGLANet 在部分指标上不如 SAFINet 和 DAFNet, 但是 EGLANet 模型参数量仅 1.75 M, 而 SAFINet 模型参数量为 3.12 M, DAFNet 模型参数量则高达 29.35 M, 所以 EGLANet 更加轻量化。

Table 1. Quantitative evaluation results of different models. Note that “↑” (“↓”) indicates that a higher (lower) value indicates better performance, and the optimal value in each column has been bolded

表 1. 不同模型的定量评估数值结果。需注意, “↑” (“↓”) 表示数值越大(越小)性能越优, 此外每列最优值已加粗

	Sm↑	adpFm↑	meanFm↑	maxFm↑	IoU↑	MAE↓
VOS	0.5083	0.1843	0.2115	0.2776	0.2034	0.2096
SMFF	0.5405	0.2089	0.3011	0.5208	0.3935	0.1434
CMC	0.5800	0.2009	0.2696	0.3272	0.2365	0.1057
LVNet	0.8644	0.6306	0.7356	0.7824	0.6734	0.0145
DAFNet-R	0.9184	0.6522	0.7980	0.8734	0.7765	0.0053
DAFNet-V	0.9166	0.6423	0.7842	0.8612	0.7702	0.0060
ERPNet-R	0.9252	0.7170	0.8269	0.8743	0.8045	0.0082
ERPNet-V	0.9210	0.7554	0.8304	0.8632	0.7887	0.0089
CSNet	0.8364	0.6319	0.7656	0.8341	0.7436	0.0169
SAMNet	0.8622	0.6114	0.7214	0.7813	0.6671	0.0132
CorrNet	0.9291	0.8322	0.8591	0.8778	0.8051	0.0084
SAFINet	0.9267	0.8575	0.8710	0.8799	0.8015	0.0065
EGLANet	0.9301	0.8468	0.8666	0.8827	0.8074	0.0061

由图 7 可知, EGLANet 的 PR 曲线虽与其他对比模型的曲线相互重叠, 但放大曲线右上角区域可见, EGLANet 还是比其它方法更靠近右上角。对于 F 测量值曲线, CorrNet、SAFINet 和 EGLANet 三条曲线重叠在一起, 覆盖面积相近并且大于其它方法。总的来说, EGLANet 还是优于其它方法。

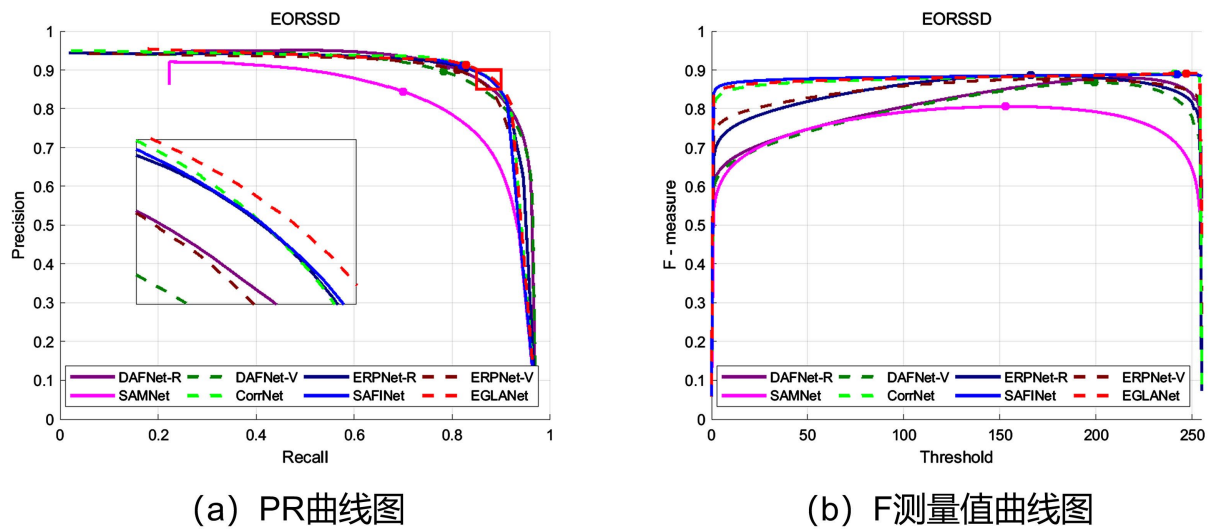


Figure 7. Quantitative evaluation curve diagram of different models. The closer the PR curve is to the upper right corner, the better it is; the larger the coverage area of the F-measure curve, the better it is

图 7. 不同模型的定量评估曲线图。PR 曲线越靠近右上角越优，F 测量值曲线覆盖面积越大越优

综上，EGLANet 在显著目标检测的精准度、目标区域完整性及与真实标签的匹配度上均具备明显优势，能够更准确、完整地检测出显著目标区域，有效降低误检与漏检风险；同时通过轻量化网络设计，进一步减少了模型参数量与计算成本，在检测精度与轻量化之间实现了更优的平衡，综合性能在所有对比模型中处于领先水平。

3.2.3. 超参数敏感性分析

在前面实验中，超参数 α 取值为 0.5，该设置已经取得了良好的实验结果。为了证实其有效性，我们针对 α 进行线性搜索实验，但进行穷尽搜索的时间成本过高，所以我们只补充取值为 0.3、0.4、0.6 和 0.7 的四组实验，然后通过四项评价指标展示模型性能的变化趋势(见图 8)。图中 Smeasure、maxFm 和 meanIoU 曲线对应左侧 y 轴，MAE 曲线对应右侧 y 轴。由图可知，四项指标的曲线变化相对平稳，这表明所提模型对超参数的敏感性较低，进而证得 α 取值为 0.5 的合理性。




Figure 8. Hyperparameter sensitivity

图 8. 超参数敏感性

4. 总结

针对光学遥感图像显著目标检测中现有模型参数量大、计算成本高或边缘信息利用不足导致目标边缘模糊的问题, 本文提出了一种边缘引导的轻量型注意力网络模型 EGLANet, 实现了光学遥感图像显著目标的轻量化、高精度检测, 与众多先进方法对比中处于领先地位, 为光学遥感图像显著目标检测提供了一种高效的轻量化解决方案, 在无人机航拍、卫星遥感监测等资源受限的实际应用场景中具备良好的部署前景。后续研究可进一步探究在目标检测模块中边缘信息引导切入的更优位置, 以及进一步压缩模型体积, 提升模型的推理速度, 实现更高效的工程化部署。

参考文献

- [1] Wang, W., Lai, Q., Fu, H., Shen, J., Ling, H. and Yang, R. (2022) Salient Object Detection in the Deep Learning Era: An In-Depth Survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **44**, 3239-3259. <https://doi.org/10.1109/tpami.2021.3051099>
- [2] Cong, R., Lei, J., Fu, H., *et al.* (2018) Review of Visual Saliency Detection with Comprehensive Information.
- [3] Borji, A., Cheng, M., Hou, Q., Jiang, H. and Li, J. (2019) Salient Object Detection: A Survey. *Computational Visual Media*, **5**, 117-150. <https://doi.org/10.1007/s41095-019-0149-9>
- [4] Simonyan, K. and Zisserman, A. (2015) Very Deep Convolutional Networks for Large-Scale Image Recognition. *3rd International Conference on Learning Representations, ICLR 2015, San Diego, 7-9 May 2015*, 1-14.
- [5] He, K., Zhang, X., Ren, S. and Sun, J. (2016) Deep Residual Learning for Image Recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, 27-30 June 2016, 770-778. <https://doi.org/10.1109/cvpr.2016.90>
- [6] Ahsan, U., Madhok, R. and Essa, I. (2019) Video Jigsaw: Unsupervised Learning of Spatiotemporal Context for Video Action Recognition. *2019 IEEE Winter Conference on Applications of Computer Vision (WACV)*, Waikoloa Village, 7-11 January 2019, 179-189. <https://doi.org/10.1109/wacv.2019.00025>
- [7] Wang, L., Lu, H. and Yang, M. (2018) Constrained Superpixel Tracking. *IEEE Transactions on Cybernetics*, **48**, 1030-1041. <https://doi.org/10.1109/tcyb.2017.2675910>
- [8] Wang, D., Lu, H. and Bo, C. (2015) Visual Tracking via Weighted Local Cosine Similarity. *IEEE Transactions on Cybernetics*, **45**, 1838-1850. <https://doi.org/10.1109/tcyb.2014.2360924>
- [9] Li, X., Han, Z., Wang, L. and Lu, H. (2016) Visual Tracking via Random Walks on Graph Model. *IEEE Transactions on Cybernetics*, **46**, 2144-2155. <https://doi.org/10.1109/tcyb.2015.2466437>
- [10] Liu, Z., Zhao, D., Shi, Z. and Jiang, Z. (2019) Unsupervised Saliency Model with Color Markov Chain for Oil Tank Detection. *Remote Sensing*, **11**, Article No. 1089. <https://doi.org/10.3390/rs11091089>
- [11] Li, C., Cong, R., Hou, J., Zhang, S., Qian, Y. and Kwong, S. (2019) Nested Network with Two-Stream Pyramid for Salient Object Detection in Optical Remote Sensing Images. *IEEE Transactions on Geoscience and Remote Sensing*, **57**, 9156-9166. <https://doi.org/10.1109/tgrs.2019.2925070>
- [12] Zhang, Q., Cong, R., Li, C., Cheng, M., Fang, Y., Cao, X., *et al.* (2021) Dense Attention Fluid Network for Salient Object Detection in Optical Remote Sensing Images. *IEEE Transactions on Image Processing*, **30**, 1305-1317. <https://doi.org/10.1109/tip.2020.3042084>
- [13] Zhou, X., Shen, K., Weng, L., Cong, R., Zheng, B., Zhang, J., *et al.* (2023) Edge-Guided Recurrent Positioning Network for Salient Object Detection in Optical Remote Sensing Images. *IEEE Transactions on Cybernetics*, **53**, 539-552. <https://doi.org/10.1109/tcyb.2022.3163152>
- [14] Li, G., Liu, Z., Bai, Z., Lin, W. and Ling, H. (2022) Lightweight Salient Object Detection in Optical Remote Sensing Images via Feature Correlation. *IEEE Transactions on Geoscience and Remote Sensing*, **60**, 1-12. <https://doi.org/10.1109/tgrs.2022.3145483>
- [15] Luo, H., Wang, J. and Liang, B. (2024) Spatial Attention Feedback Iteration for Lightweight Salient Object Detection in Optical Remote Sensing Images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, **17**, 13809-13823. <https://doi.org/10.1109/jstars.2024.3435385>
- [16] Sandler, M., Howard, A., Zhu, M., Zhmoginov, A. and Chen, L. (2018) MobileNetV2: Inverted Residuals and Linear Bottlenecks. *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Salt Lake City, 18-22 June 2018, 4510-4520. <https://doi.org/10.1109/cvpr.2018.00474>
- [17] Howard, A., Sandler, M., Chen, B., Wang, W., Chen, L., Tan, M., *et al.* (2019) Searching for MobileNetV3. 2019

-
- IEEE/CVF International Conference on Computer Vision (ICCV)*, Seoul, 27-28 October 2019, 1314-1324.
<https://doi.org/10.1109/iccv.2019.00140>
- [18] Woo, S., Park, J., Lee, J. and Kweon, I.S. (2018) CBAM: Convolutional Block Attention Module. *Computer Vision—ECCV 2018 15th European Conference*, Munich, 8-14 September 2018, 3-19.
https://doi.org/10.1007/978-3-030-01234-2_1
- [19] Li, G., Liu, Z., Lin, W. and Ling, H. (2022) Multi-Content Complementation Network for Salient Object Detection in Optical Remote Sensing Images. *IEEE Transactions on Geoscience and Remote Sensing*, **60**, 1-13.
<https://doi.org/10.1109/tgrs.2021.3131221>
- [20] Li, G., Liu, Z., Chen, M., Bai, Z., Lin, W. and Ling, H. (2021) Hierarchical Alternate Interaction Network for RGB-D Salient Object Detection. *IEEE Transactions on Image Processing*, **30**, 3528-3542.
<https://doi.org/10.1109/tip.2021.3062689>
- [21] Qin, X., Zhang, Z., Huang, C., Gao, C., Dehghan, M. and Jagersand, M. (2019) Basnet: Boundary-Aware Salient Object Detection. 2019 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Long Beach, 16-20 June 2019, 7479-7489. <https://doi.org/10.1109/cvpr.2019.00766>
- [22] Zhang, Q., Zhang, L., Shi, W. and Liu, Y. (2018) Airport Extraction via Complementary Saliency Analysis and Saliency-Oriented Active Contour Model. *IEEE Geoscience and Remote Sensing Letters*, **15**, 1085-1089.
<https://doi.org/10.1109/lgrs.2018.2828502>
- [23] Zhang, L., Liu, Y. and Zhang, J. (2019) Saliency Detection Based on Self-Adaptive Multiple Feature Fusion for Remote Sensing Images. *International Journal of Remote Sensing*, **40**, 8270-8297.
<https://doi.org/10.1080/01431161.2019.1608384>
- [24] Gao, S., Tan, Y., Cheng, M., Lu, C., Chen, Y. and Yan, S. (2020) Highly Efficient Salient Object Detection with 100K Parameters. *Computer Vision—ECCV 2020 16th European Conference*, Glasgow, 23-28 August 2020, 702-721.
https://doi.org/10.1007/978-3-030-58539-6_42
- [25] Liu, Y., Zhang, X., Bian, J., Zhang, L. and Cheng, M. (2021) Samnet: Stereoscopically Attentive Multi-Scale Network for Lightweight Salient Object Detection. *IEEE Transactions on Image Processing*, **30**, 3804-3814.
<https://doi.org/10.1109/tip.2021.3065239>