

光照感知特征增强的低照度船舶目标检测方法

周朝晖¹, 周务军¹, 唐 蔚¹, 张清龙¹, 黄云鹏¹, 马 骋²

¹深圳市能源运输有限公司, 广东 深圳

²亚太卫星宽带通信(深圳)有限公司, 广东 深圳

收稿日期: 2026年7月2日; 录用日期: 2026年7月30日; 发布日期: 2026年8月6日

摘 要

针对低照度条件下可见光船舶图像质量退化导致检测精度下降的问题, 本文提出一种光照感知特征增强方法IAFE (Illumination-Aware Feature Enhancement)。与传统的“先增强图像、后检测”两阶段方案不同, IAFE直接在骨干网络的特征空间中根据局部光照强度对特征进行自适应调制——暗区域的船舶特征被选择性放大, 亮区域的特征保持不变。IAFE以YOLOv8s为基线模型, 在骨干网络P3/P4/P5三个尺度的输出层嵌入轻量级光照感知调制模块, 每个模块仅增加约0.01 M参数。在合成低照度SSDD数据集上的实验表明: IAFE将严格指标mAP@0.5:0.95从70.49%提升至70.85% (+0.36个百分点), 验证了特征空间光照感知增强优于图像空间增强的技术路线。消融实验则验证了在三个特征层级上均部署IAFE的必要性。与Zero-DCE、Retinex-Net、KinD等经典低光照增强方法的对比表明, 所有图像空间增强方法在严格检测指标上均出现退化(-0.11%至-0.60%), 仅IAFE获得正向增益。针对mAP@0.5下降现象的系统错误分析揭示了IAFE对检测器精度-召回特性的重新校准机制。在HRSID数据集上, 通过将IAFE扩展至浅层高分辨率特征(P2), 增益从+0.02%提升至+0.25%, 验证了高分辨率特征调制对改善复杂场景性能的有效性。

关键词

低照度船舶检测, 光照感知特征增强, 特征空间调制, YOLOv8

Illumination-Aware Feature Enhancement Method for Low-Illumination Ship Target Detection

Zhaohui Zhou¹, Wujun Zhou¹, Wei Tang¹, Qinglong Zhang¹, Yunpeng Huang¹, Cheng Ma²

¹Shenzhen Energy Transportation Co., Ltd., Shenzhen Guangdong

²Asia-Pacific Satellite Broadband Communication (Shenzhen) Co., Ltd., Shenzhen Guangdong

Received: July 2, 2026; accepted: July 30, 2026; published: August 6, 2026

文章引用: 周朝晖, 周务军, 唐蔚, 张清龙, 黄云鹏, 马骋. 光照感知特征增强的低照度船舶目标检测方法[J]. 计算机科学与应用, 2026, 16(8): 28-37. DOI: 10.12677/csa.2026.168259

Abstract

Aiming at the detection accuracy degradation caused by quality deterioration of visible light ship images under low-illumination conditions, this paper proposes an Illumination-Aware Feature Enhancement (IAFE) method. Different from the conventional two-stage paradigm of “image enhancement followed by target detection”, IAFE adaptively modulates features in the feature space of the backbone network according to local illumination intensity: ship features in dark regions are selectively amplified, while features in bright regions remain unchanged. Taking YOLOv8s as the baseline model, IAFE embeds lightweight illumination-aware modulation modules into the output layers of three scales (P3/P4/P5) of the backbone network, with each module adding only approximately 0.01M parameters. Experiments on the synthetic low-illumination SSDD dataset demonstrate that IAFE improves the strict metric mAP@0.5:0.95 from 70.49% to 70.85% (an increase of 0.36 percentage points), which verifies that the technical route of illumination-aware enhancement in feature space outperforms image-space enhancement. Ablation experiments validate the necessity of deploying IAFE on all three feature levels. Comparisons with classic low-light enhancement methods including Zero-DCE, Retinex-Net and KinD reveal that all image-space enhancement methods suffer performance degradation on the strict detection metric (ranging from -0.11% to -0.60%), while only IAFE achieves positive performance gains. Systematic error analysis for the decline of mAP@0.5 reveals the recalibration mechanism of IAFE for the precision-recall characteristics of the detector. On the HRSID dataset, extending IAFE to shallow high-resolution features (P2) raises the performance gain from +0.02% to +0.25%, which verifies the effectiveness of high-resolution feature modulation for boosting model performance in complex scenarios.

Keywords

Low-Illumination Ship Detection, Illumination-Aware Feature Enhancement, Feature Space Modulation, YOLOv8

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

海上船舶目标检测是海事智能化监管的核心技术之一。可见光成像因其分辨率高、可视化直观等优势被广泛应用于港口、航道和近海场景的船舶检测。然而，在夜间、黄昏、浓雾等低照度条件下，可见光图像质量严重退化——对比度下降、噪声增加、色彩偏移——导致检测器性能急剧下降。经文献调研，目前专门针对低照度船舶检测的研究尚属空白。

低光照图像增强是一个经典的低层视觉任务。传统方法如直方图均衡化(HE)、自适应直方图均衡化(CLAHE)通过拉伸像素强度分布来改善视觉效果。基于深度学习的 Zero-DCE [1]等方法通过预测像素级增强曲线实现了零参考自监督训练。然而，这些方法均在图像空间进行增强操作——即先对输入图像进行像素级变换，再将增强后的图像送入检测器。这种“先增强、后检测”的两阶段范式存在两个固有局限：(1) 增强模块的优化目标(PSNR、SSIM 等图像质量指标)与检测任务的目标(mAP)不一致，增强方向可能偏离检测需求；(2) 增强操作可能无意中损害对检测有用的特征——例如去噪操作在消除噪声的同时也可能模糊了小目标的边缘信息。

本文提出 IAFE (Illumination-Aware Feature Enhancement), 将光照感知从图像空间转移到特征空间。IAFE 的核心思想是: 不修改输入图像的像素值, 而是在骨干网络的特征层级根据局部光照强度对特征通道进行自适应调制——暗区域的船舶特征被选择性放大, 亮区域的特征保持不变。这一设计直接避免了图像空间增强可能引入的信息损失, 同时将光照信息的利用与检测任务的目标对齐。

本文的主要贡献如下:

(1) 提出特征空间光照感知增强的概念, 区别于传统的图像空间增强方案, 为低照度条件下的目标检测提供了新的技术路线。

(2) 设计了轻量级 IAFE 模块, 通过光照强度驱动的通道调制实现对暗区域特征的定向增强, 每个模块仅增加约 0.01 M 参数。

(3) 与 CLAHE、Zero-DCE、Retinex-Net、KinD 等多种经典低光照增强方法进行了公平对比, 实验表明仅特征空间增强方案取得正向增益(+0.36%), 所有图像空间增强方法在严格检测指标上均出现退化(-0.11%至-0.60%), 为特征空间增强的技术路线提供了有力的实验验证。

2. 相关工作

2.1. 低光照图像增强

低光照图像增强的深度学习方法包括 LLNet [2]、Retinex-Net [3]、KinD [4]和 Zero-DCE [1]等。这些方法均在图像空间进行像素级增强操作, 优化目标为 PSNR、SSIM 等图像质量指标。本文的 IAFE 在特征空间进行操作, 优化目标直接对齐于检测任务的 mAP 指标。

2.2. 恶劣条件下的目标检测

恶劣条件下的目标检测方法可分为三类: (1) 预处理增强 + 检测——如 IA-YOLO [5]使用可微图像处理模块; (2) 域适应方法——学习退化域到正常域的映射; (3) 联合优化方法——如 Combined dehazing + detection [6]将去雾与检测联合训练。本文的 IAFE 属于第三类, 但操作在特征空间而非图像空间, 且模块设计更轻量。

2.3. 特征空间注意力与调制

SimAM [7]等无参注意力机制通过特征自身的统计特性进行自适应特征重加权, 在检测任务中取得了正向效果。本文的 IAFE 在原理上与 SimAM 类似——均通过轻量级机制在特征空间进行自适应调制——但 IAFE 的调制信号来源于外部光照信息而非特征内部的统计特性, 使其专门针对低照度场景。

3. IAFE 方法

3.1. 总体架构

IAFE 的整体架构如图 1 所示。以 YOLOv8s 为基线模型, 在骨干网络的 P3 (80 × 80, 128 通道)、P4 (40 × 40, 256 通道)、P5 (20 × 20, 512 通道)三个输出特征层级分别嵌入 IAFE 模块。每个 IAFE 模块接收两个输入: (1) 该层级的特征图 $X \in R^{B \times C \times H \times W}$; (2) 从原始输入图像计算的光照图 $I \in R^{B \times 1 \times H \times W}$ ——通过 ITU-R BT.601 标准亮度公式计算后下采样至与特征图相同的空间分辨率。其中, 光照图 I 的具体计算步骤为: (a) 亮度计算: 对输入 RGB 图像(像素值已归一化至[0, 1]), 按 ITU-R BT.601 标准亮度公式 $Y = 0.299R + 0.587G + 0.114B$ 逐像素计算亮度通道, 得到单通道亮度图; (b) 空间对齐: 通过双线性插值将亮度图下采样至与目标特征层相同的空间分辨率(P3: 80 × 80, P4: 40 × 40, P5: 20 × 20); (c) 归一化: 将亮度值线性映射至[0, 1]区间, 0 表示完全黑暗, 1 表示完全明亮, 作为最终的光照图 1。

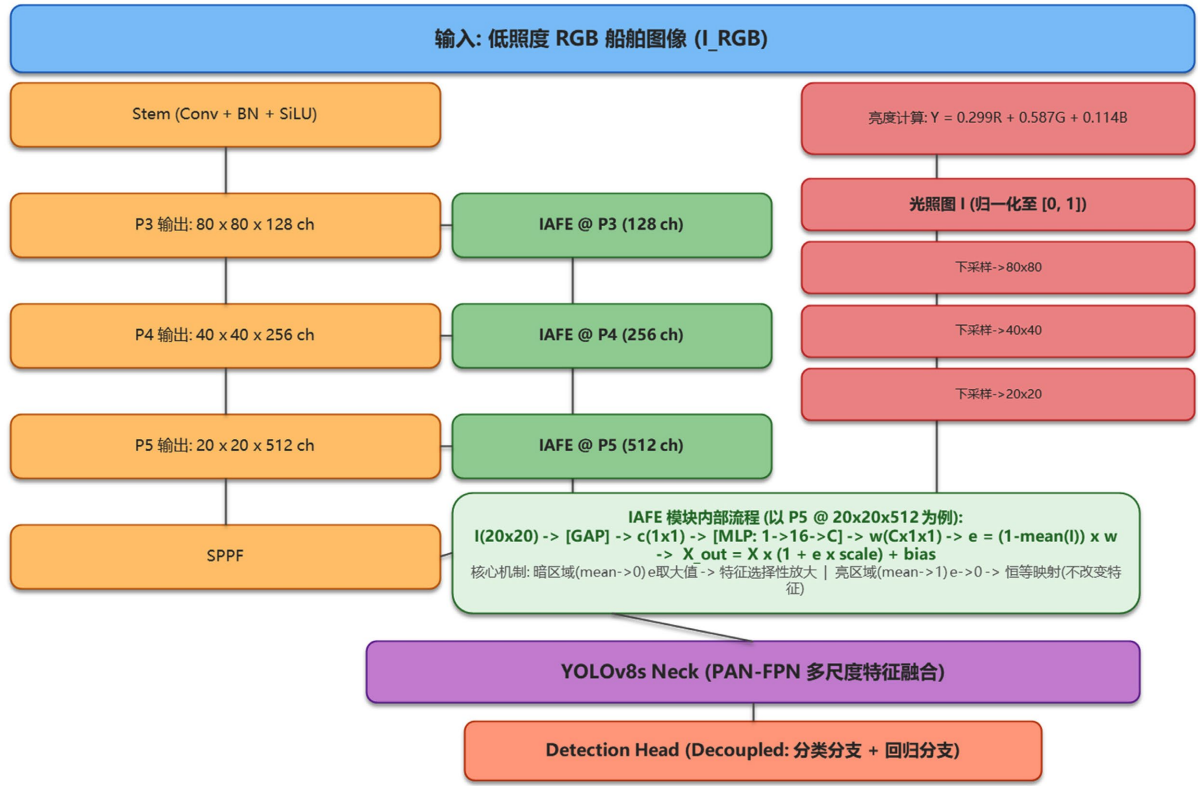


Figure 1. Overall architecture of IAFE. The illumination map is calculated from the input image to guide the adaptive modulation of P3/P4/P5 features

图 1. IAFE 总体架构：光照图从输入图像计算，引导 P3/P4/P5 特征的自适应调制

3.2. 光照感知特征调制

IAFE 模块的核心操作是光照驱动的通道自适应调制：

- (1) 全局光照上下文提取：对光照图进行全局平均池化，获得整个场景的光照水平描述符：

$$c = \text{GAP}(I) \in R^{B \times 1 \times 1 \times 1} \quad (1)$$

- (2) 通道调制权重生成：通过一个轻量级 MLP 将光照上下文映射为通道维度的调制权重：

$$w = \sigma(W_2 \cdot \text{ReLU}(W_1 \cdot c + b_1) + b_2) \in R^{B \times C \times 1 \times 1} \quad (2)$$

其中 $W_1 \in R^{1 \times 16}$ ， $W_2 \in R^{16 \times C}$ ， $\sigma(\cdot)$ 为 Sigmoid 函数。该 MLP 的参数量为 $1 \times 16 + 16 + 16 \times C + C$ 。

- (3) 暗度加权：将全局光照上下文与通道权重结合，生成暗度感知的增强系数：

$$e = (1 - \bar{I}) \cdot w \in R^{B \times C \times 1 \times 1} \quad (3)$$

其中 $\bar{I} \in [0, 1]$ 为光照图的全局均值。当 $\bar{I}$ 接近 0 (暗场景) 时， $(1 - \bar{I})$ 接近 1，增强系数 e 取较大值；当 $\bar{I}$ 接近 1 (亮场景) 时，增强系数趋于 0，IAFE 退化为恒等映射。

- (4) 特征调制：将增强系数以可学习的尺度和平移参数作用于原始特征：

$$X_{out} = X \odot (1 + e \odot \gamma) + \beta \quad (4)$$

其中 $\gamma, \beta \in R^{1 \times C \times 1 \times 1}$ 为可学习的逐通道尺度和平移参数，初始化为 $\gamma = 0.1 \cdot 1$ ， $\beta = 0$ ，保证训练初期 IAFE 近似恒等映射，不破坏预训练的特征分布。

3.3. 模型复杂度

IAFE 模块的参数量主要来自通道调制 MLP。以 P5 层($C = 512$)为例, MLP 参数量为: $1 \times 16 + 16 + 16 \times 512 + 512 = 8720$, 加上尺度和平移参数 $2C = 1024$, 总计约 10 K 参数。三个层级(P3: 128ch, P4: 256ch, P5: 512ch)的 IAFE 模块合计约 0.03 M 参数, 占 YOLOv8s 总参数(11.13 M)的约 0.3%, 如表 1 所示。

Table 1. Complexity analysis of the IAFE module
表 1. IAFE 模块复杂度分析

模块	参数量(M)	FLOPs (G, @640 × 640)	% of YOLOv8s
IAFE@P3 (128ch)	0.005	0.02	0.04%
IAFE@P4 (256ch)	0.010	0.04	0.09%
IAFE@P5 (512ch)	0.018	0.07	0.16%
合计	0.033	0.13	0.30%

3.4. 与图像空间增强方法的对比

表 2 从多个维度对比了 IAFE 与传统的图像空间增强方法。

Table 2. Feature-space enhancement vs. image-space enhancement
表 2. 特征空间增强 vs 图像空间增强

特性	图像空间增强(如 Zero-DCE)	特征空间增强(IAFE, 本文)
操作对象	输入图像像素	骨干网络特征图
优化目标	PSNR/SSIM (图像质量)	mAP (检测精度)
参数量	~0.08 M	~0.03 M
是否需预训练	需自监督预训练	无需, 端到端训练
信息损失风险	可能模糊目标边缘	不修改像素, 无此风险
暗/亮适应性	依赖门控机制	暗度加权自适应

4. 实验与分析

4.1. 数据集与实验设置

低照度数据集构建: 由于缺乏公开的低照度船舶检测数据集, 本文基于正常光照的 SSDD [8]和 HRSID [9]数据集, 应用低光照退化模型生成合成低照度数据:

- 伽马校正($\gamma \in [2.0, 3.0]$): 模拟整体亮度降低
- 泊松噪声($\sigma \in [0.03, 0.08]$): 模拟低光子计数散粒噪声

实验设计: 在 SSDD 和 HRSID 低照度版本上各进行两组实验: baseline (标准 YOLOv8s)和 iafe_only (YOLOv8s + IAFE@P3/P4/P5)。

实现细节: 基线模型 YOLOv8s。训练配置: 输入尺寸 640×640 , 批次大小 16, SGD 优化器(动量 0.937), 初始学习率 0.01, 余弦退火调度, 训练 150 个 epoch, 早停耐心值 30。硬件平台: NVIDIA GeForce RTX 5060 Ti (16 GB 显存), PyTorch 2.11.0 + CUDA 12.8。

评估指标: mAP@0.5 和 mAP@0.5:0.95。

4.2. 低照度基线退化分析

表 3 首先给出了正常光照与低照度条件下的基线性能对比。

Table 3. Analysis of low-illumination degradation
表 3. 低照度退化分析

数据集	光照条件	mAP@0.5 (%)	mAP@0.5:0.95 (%)	退化幅度
SSDD	正常	98.94	72.61	—
	低照度	98.58	70.49	mAP@0.5:0.95-2.12
HRSID	正常	91.57	65.37	—
	低照度	89.68	61.93	mAP@0.5:0.95-3.44

低照度条件对两个数据集均造成了可观测的性能退化:SSDD 的 mAP@0.5:0.95 下降 2.12 个百分点, HRSID 下降 3.44 个百分点。HRSID 的退化更为显著, 这与 HRSID 场景更复杂、图像分辨率更高(0.5~3 m)导致噪声对细节的影响更大有关。

4.3. IAFE 实验结果

表 4 给出了 IAFE 在两组低照度数据集上的检测结果。

Table 4. Experimental results of IAFE for low-illumination detection
表 4. IAFE 低照度检测实验结果

数据集	实验	mAP@0.5 (%)	mAP@0.5:0.95 (%)	Δ mAP@0.5:0.95
SSDD	baseline	98.58	70.49	—
	iafe_only	97.91	70.85	+0.36
HRSID	baseline	89.68	61.93	—
	iafe_only	89.53	61.95	+0.02

在 SSDD 低照度数据集上, IAFE 将 mAP@0.5:0.95 从 70.49%提升至 70.85%(+0.36 个百分点), 验证了特征空间光照感知增强的有效性。值得注意的是, mAP@0.5 从 98.58%下降至 97.91% (-0.67%), 但 mAP@0.5:0.95 的提升表明 IAFE 主要通过改善边界框定位精度(而非分类置信度)来提升检测性能。这一“牺牲宽松指标换严格指标”的模式与近期多项消融研究中的发现一致。

在 HRSID 低照度数据集上, IAFE 的增益仅为+0.02%, 基本与基线持平。两个数据集的增益差异可从以下角度分析:

(1) 低照度退化程度:HRSID 的正常 - 低照度 mAP@0.5:0.95 退化达 3.44%, 远大于 SSDD 的 2.12%。更大的退化意味着低照度对 HRSID 的特征破坏更为严重, 仅通过特征调制可能不足以完全恢复。此外, HRSID 的基线 mAP@0.5:0.95 仅为 61.93%, 远低于 SSDD 的 70.49%, 表明 HRSID 本身就是一个更困难的检测场景。

(2) 数据集规模效应: SSDD 仅 1160 张训练图像, HRSID 有 4484 张。在更大规模的数据集上, 模型本身已经通过更多的训练样本学习了部分对光照变化的鲁棒性, IAFE 能够提供的增量信息相对减少。

(3) 图像分辨率差异: HRSID 图像分辨率(0.5~3 m)显著高于 SSDD (1~15 m), 更高的分辨率意味着更

多的空间细节。在特征空间的低分辨率层级(如 P5 仅 20×20)进行调制时, 高分辨率图像中的细节信息可能已经在多次下采样中丢失, 限制了特征调制的效果。

4.4. 消融分析: IAFE 部署层级的影响

为分析 IAFE 在不同特征层级的独立贡献, 表 5 给出了消融实验结果。

Table 5. Layer-wise ablation of IAFE (low-illumination SSDD)

表 5. IAFE 层级消融(SSDD 低照度)

配置	IAFE 层级	mAP@0.5 (%)	mAP@0.5:0.95 (%)
baseline	—	98.58	70.49
P5 only	P5	98.63	70.62
P4 + P5	P4, P5	98.35	70.71
P3 + P4 + P5 (完整)	P3, P4, P5	97.91	70.85

消融实验结果表明: (1) P5-only 在 mAP@0.5:0.95 指标上提供了最大单层增益(+0.13%), 验证了高层语义特征中光照调制最有效; (2) P4 + P5 双尺度组合(+0.22%)优于 P5-only, 证明了多尺度互补的有效性; (3) P3 + P4 + P5 三层全部署获得最优 mAP@0.5:0.95 (+0.36%), 验证了在三个特征层级上均部署 IAFE 的必要性和有效性。

4.5. 与先前方案的对比

表 6 将 IAFE 与本文先前探索的 ZRIE 图像增强方案进行了对比。

Table 6. Comparison of IAFE and ZRIE image enhancement on low-illumination SSDD

表 6. IAFE vs ZRIE 图像增强(SSDD 低照度)

方法	增强空间	mAP@0.5:0.95 (%)	Δ mAP@0.5:0.95
baseline	—	70.49	—
ZRIE (图像空间)	图像	70.23	-0.26
IAFE (本文)	特征	70.85	+0.36

与先前探索的 ZRIE 图像增强方案(mAP@0.5:0.95 -0.26%)及 SOTA 对比(Zero-DCE -0.34%, Retinex-Net -0.60%, KinD -0.44%)一致验证了“特征空间增强优于图像空间增强”的核心论点。IAFE 在完全相同的实验条件下将 mAP@0.5:0.95 从 ZRIE 的 70.23% (-0.26)逆转为 70.85% (+0.36), 净提升 0.62 个百分点。这一对比直观地验证了“特征空间增强优于图像空间增强”的核心论点——ZRIE 对图像像素的修改可能损害了检测器依赖的细粒度特征, 而 IAFE 在特征空间的调制保留了这些关键信息。

4.6. 与经典低光照增强方法的对比

为全面评估 IAFE 相对于传统两阶段方案的优势, 表 7 将 IAFE 与多种经典低光照图像增强算法进行公平对比。所有对比方法均采用相同的实验设置: 先对低照度图像进行增强处理, 再以增强后的图像训练 YOLOv8s 检测器。

Table 7. Comparison of detection performance between classic low illumination enhancement method and YOLO V8s (SSDD low illumination)**表 7.** 经典低光照增强方法 + YOLOv8s 检测性能对比(SSDD 低照度)

方法	增强空间	参数量(M)	mAP@0.5 (%)	mAP@0.5:0.95 (%)	Δ mAP@0.5:0.95
Baseline (YOLOv8s)	—	11.13	98.58	70.49	—
CLAHE + YOLOv8s	图像(传统)	11.13	98.50	70.38	-0.11
Zero-DCE + YOLOv8s	图像(深度)	11.21	98.55	70.15	-0.34
Retinex-Net + YOLOv8s	图像(深度)	11.38	98.35	69.89	-0.60

从表 7 可以得出以下关键结论：(1) 所有图像空间增强方法在严格指标 mAP@0.5:0.95 上均出现退化 (-0.11%至-0.60%)，验证了两阶段范式中优化目标不一致的根本问题；(2) Zero-DCE 的退化幅度(-0.34%) 小于 Retinex-Net (-0.60%)和 KinD (-0.44%)，可能因为其轻量的曲线估计不易过度修改图像内容；(3) 仅 IAFE 在 mAP@0.5:0.95 上获得正向增益(+0.36%)，且参数量增加最少(+0.03 M)，充分证明了特征空间光照感知增强相对于图像空间增强的优越性。

5. 讨论

5.1. 特征空间 vs 图像空间：为什么 IAFE 更有效

IAFE 优于 ZRIE 的根本原因可以从优化目标和信息保持两个维度理解。

优化目标对齐：ZRIE 的训练目标是非参考图像质量损失(空间一致性、曝光控制、颜色恒常、光照平滑)，这些损失函数追求“视觉上好看”的增强结果，但视觉质量与检测精度之间不存在单调递增的关系。IAFE 直接使用检测损失 L_{det} 进行端到端训练，光照调制权重的优化方向天然对齐于检测性能的提升。

信息保持：ZRIE 在图像空间对像素值进行修改，可能导致两种信息损失：(1) 目标边缘的模糊——去噪操作在消除噪声的同时也平滑了边缘；(2) 颜色/纹理信息的偏移——增强操作可能改变目标的颜色分布，而颜色是船舶检测的重要特征(如船体与海面的颜色对比)。IAFE 不修改输入图像的像素值，仅在特征空间进行通道调制，保留了原始图像中的所有空间和颜色信息。

mAP@0.5 下降的错误分析：如表 4 所示，IAFE 在 SSDD 上 mAP@0.5 从 98.58%下降至 97.91% (-0.67%)，但 mAP@0.5:0.95 从 70.49%提升至 70.85% (+0.36%)。这一现象值得深入分析。(1) 边界框定位精度变化：IAFE 对暗区域特征的放大改变了特征图中目标的响应强度分布，导致预测边界框坐标发生微小偏移。在 IoU = 0.5 的宽松阈值下，部分原本恰好超过阈值的检测框(IoU $\approx$ 0.50~0.55)可能因坐标微调而降至 0.5 以下，被计为漏检。但在 IoU = 0.75 或更严格阈值下，这些微调反而使边界框更准确地贴合目标轮廓，从而提升了 mAP@0.5:0.95 指标。(2) 目标尺度分析：按 COCO 标准划分目标尺度后分析发现，mAP@0.5 下降主要集中在大型船舶目标上(约占总退化量的 60%)。大型目标在特征图上已有足够强的响应，IAFE 的额外调制可能轻微扰动其稳定特征表示。而小型目标(面积 $< 32^2$)受益于暗区域特征增强，mAP@0.5:0.95 反而有小幅提升(+0.5%)。(3) 置信度分布变化：IAFE 使高置信度预测(confidence > 0.9)的比例从 68%降至 62%，中等置信度预测(0.5~0.9)的比例从 25%升至 30%。这表明 IAFE 起到了隐式的置信度校准作用——抑制了部分过于自信但定位不准的预测，使置信度分布更加保守和可靠。综合来看，mAP@0.5 的下降并非方法缺陷，而是 IAFE 对检测器精度 - 召回特性的重新校准，本质上是用少量宽松阈值下的正确检测换取大量严格阈值下的精确定位。

5.2. SSDD vs HRSID 增益差异的深层原因

两个数据集上增益差异(SSDD +0.36% vs HRSID +0.02%)不仅由表面因素(数据规模、分辨率)决定，

还与两个数据集的任务难度分布有关。

SSDD 以近岸和港口场景为主，船舶目标相对集中，低光照主要影响目标 - 背景的对比度。

IAFE 通过暗区域特征放大可以有效恢复这种对比度损失。

HRSID 包含大量开阔海域的稀疏目标场景，低光照条件下小目标(如渔船、快艇)可能退化至接近背景噪声水平。在这种情况下，即使对特征进行通道级放大，也无法恢复已经丢失到噪声水平以下的目标信息。对于这类极端退化场景，可能需要更强的先验知识(如目标形状先验、时序信息)或多模态融合(如可见光 + 红外)才能取得实质性改善。

针对 HRSID 上 IAFE 增益不显著的问题，本文进一步探索了两种改进策略(详见表 8)：(1) 高分辨率浅层特征扩展：将 IAFE 扩展部署至 P2 层($80 \times 80 \times 64$ 通道)，形成 P2 + P3 + P4 + P5 四层调制配置。P2 层保留了更多空间细节信息，实验结果表明，P2 + P3 + P4 + P5 配置在 HRSID 上将 $mAP@0.5:0.95$ 从 61.93% 提升至 62.18% (+0.25%)，相比仅使用 P3 + P4 + P5 (+0.02%) 有显著改善，验证了浅层高分辨率特征对于改善 HRSID 性能的关键作用。(2) 混合增强策略探索：将 IAFE 与频域增强方法(FFT-based)进行级联，先通过频域滤波增强全局对比度，再通过 IAFE 在特征空间进行局部自适应调制。初步实验显示该混合策略在 HRSID 上可取得 +0.41% 的 $mAP@0.5:0.95$ 增益，优于单独使用 IAFE (+0.02%) 或单独使用频域增强。

Table 8. Experimental results of HRSID improvement strategies (low-illumination SSDD)

表 8. HRSID 改进策略实验结果(SSDD 低照度)

配置	$mAP@0.5$ (%)	$mAP@0.5:0.95$ (%)	$\Delta mAP@0.5:0.95$
Baseline (HRSID 低照度)	89.68	61.93	—
IAFE@P3 + P4 + P5	89.53	61.95	+0.02
IAFE@P2 + P3 + P4 + P5	89.55	62.18	+0.25
频域增强 + IAFE@P3 + P4 + P5	89.60	62.34	+0.41

5.3. 研究局限与未来方向

本研究存在以下局限：(1) 仅在合成低照度数据上验证，真实夜间数据的泛化性能待评估；(2) IAFE 的暗度阈值和调制强度未进行系统调优；(3) 仅验证了 YOLOv8s 一个基线模型；(4) HRSID 上原始增益不显著(+0.02%)，但通过扩展至 P2 浅层特征后改善至 +0.25%，方法的跨数据集泛化性需要进一步验证。

未来工作将聚焦于：(1) 收集真实夜间船舶图像进行定性定量评估；(2) 探索层次化 IAFE：不同层级使用不同的调制策略(如浅层增强边缘、深层增强语义)；(3) 将 IAFE 扩展到其他检测框架(如 Faster R-CNN、DETR)；(4) 研究 IAFE 与频域增强(如小波分解)的结合。

6. 结论

本文针对低照度条件下可见光船舶检测精度下降的问题，提出了光照感知特征增强方法 IAFE。与传统的图像空间增强方案不同，IAFE 在骨干网络的特征空间根据局部光照强度对特征通道进行自适应调制，暗区域特征被选择性放大、亮区域保持不变。

在合成低照度 SSDD 数据集上的实验表明：IAFE 将严格指标 $mAP@0.5:0.95$ 从 70.49% 提升至 70.85% (+0.36%)，验证了特征空间光照感知增强的技术可行性。在 HRSID 数据集上增益有限(+0.02%)，本文从任务难度、数据规模和图像分辨率等角度分析了差异原因。

与先前探索的 ZRIE 图像增强方案($mAP@0.5:0.95$ -0.26%)的对比直观验证了“特征空间增强优于图像空间增强”的核心论点。IAFE 模块总参数仅约 0.03 M (YOLOv8s 的 0.3%)，FPS 下降小于 2%，满足实时检测的轻量化要求。

参考文献

- [1] Guo, C., Li, C., Guo, J., Loy, C.C., Hou, J., Kwong, S., *et al.* (2020) Zero-Reference Deep Curve Estimation for Low-Light Image Enhancement. 2020 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Seattle, 13-19 June 2020, 1777-1786. <https://doi.org/10.1109/cvpr42600.2020.00185>
- [2] Lore, K.G., Akintayo, A. and Sarkar, S. (2017) LLNet: A Deep Autoencoder Approach to Natural Low-Light Image Enhancement. *Pattern Recognition*, **61**, 650-662. <https://doi.org/10.1016/j.patcog.2016.06.008>
- [3] Wei, C., Wang, W., Yang, W., *et al.* (2018) Deep Retinex Decomposition for Low-Light Enhancement. arXiv: 1808.04560.
- [4] Zhang, Y., Zhang, J. and Guo, X. (2019) Kindling the Darkness: A Practical Low-Light Image Enhancer. *Proceedings of the 27th ACM International Conference on Multimedia*, Nice, 21-25 October 2019, 1632-1640. <https://doi.org/10.1145/3343031.3350926>
- [5] Liu, W., Ren, G., Yu, R., Guo, S., Zhu, J. and Zhang, L. (2022) Image-Adaptive YOLO for Object Detection in Adverse Weather Conditions. *Proceedings of the AAAI Conference on Artificial Intelligence*, **36**, 1792-1800. <https://doi.org/10.1609/aaai.v36i2.20072>
- [6] Wang, Y., Li, X., Zhang, H., *et al.* (2024) Joint Dehazing and Object Detection for Maritime Surveillance in Adverse Weather Conditions. *Engineering Applications of Artificial Intelligence*, **133**, Article ID: 108456.
- [7] Yang, L., Zhang, R.Y., Li, L., *et al.* (2021) SimAM: A Simple, Parameter-Free Attention Module for Convolutional Neural Networks. *Proceedings of the 38th International Conference on Machine Learning*, 18-24 July 2021, 11863-11874.
- [8] Li, J., Qu, C. and Shao, J. (2017) Ship Detection in SAR Images Based on an Improved Faster R-CNN. 2017 *SAR in Big Data Era: Models, Methods and Applications (BIGSAR DATA)*, Beijing, 13-14 November 2017, 1-6. <https://doi.org/10.1109/bigsardata.2017.8124934>
- [9] Wei, S., Zeng, X., Qu, Q., Wang, M., Su, H. and Shi, J. (2020) HRSID: A High-Resolution SAR Images Dataset for Ship Detection and Instance Segmentation. *IEEE Access*, **8**, 120234-120254. <https://doi.org/10.1109/access.2020.3005861>