

DOI:10.20079/j.issn.1001-893x.250506001

# 基于颜色通道变换增强的低照度图像目标检测算法\*

张 敏<sup>1,2</sup>, 乔文昇<sup>1,2</sup>, 朱佩佩<sup>1,2</sup>, 朱思翰<sup>1,2</sup>, 詹雨飞<sup>1,2</sup>, 黄晓晨<sup>3</sup>, 陈洪刚<sup>3</sup>

(1. 西南电子技术研究所, 成都 610036; 2. 复杂航空系统仿真全国重点实验室, 成都 610036;  
3. 四川大学 电子信息学院, 成都 610065)

**摘要:** 目标检测技术旨在从图像或视频中对特定类别目标进行定位和识别。然而, 在低照度场景中面临对比度低、边界模糊、噪声干扰等问题, 导致检测算法性能下降。为此, 提出了一种基于颜色通道变换增强的目标检测 (Color Channel Transformation Enhancement-based Object Detection, C2TEOD) 算法。首先, 构建了颜色通道变换模块, 引入可学习参数对不同颜色通道进行变换, 提升增强策略灵活性。然后, 通过一个图像增强模块对图像进行预处理, 并采用检测损失联合优化增强模块与检测网络, 使增强网络能够朝着有利于检测任务的方向优化。此外, 提出了选择性自监督回归损失, 利用原始低照度图像和增强图像输入检测网络并对其进行优化, 再根据它们的检测结果对增强模块进行自监督回归优化, 进一步提升检测效果。实验结果显示, 该算法相比基线方法在 Exdark、M3FD、LLVIP 数据集上的平均精度均值 (mean Average Precision, mAP) 分别提升 2.2%、1.1% 和 0.2%。  
**关键词:** 目标检测; 图像增强; 深度学习; 联合优化; 自监督

开放科学 (资源服务) 标识码 (OSID):



中图分类号: TP391.4 文献标志码: A 文章编号: 1001-893X(2025)11-1781-08

## Color Channel Transformation Enhancement-based Low-illumination Images Object Detection

ZHANG Min<sup>1,2</sup>, QIAO Wensheng<sup>1,2</sup>, ZHU Peipei<sup>1,2</sup>, ZHU Sihan<sup>1,2</sup>,  
ZHAN Yufei<sup>1,2</sup>, HUANG Xiaochen<sup>3</sup>, CHEN Honggang<sup>3</sup>

(1. Southwest China Institute of Electronic Technology, Chengdu 610036, China;  
2. National Key Laboratory of Complex Aviation System Simulation, Chengdu 610036, China;  
3. College of Electronics and Information Engineering, Sichuan University, Chengdu 610065, China)

**Abstract:** Object detection technology aims to locate and identify specific category targets in images or videos. However, in low-illumination scenarios, problems such as low contrast, blurred boundaries, and noise interference, result in the decline of detection performance. To address this, a Color Channel Transformation Enhancement-based Object Detection (C2TEOD) algorithm is proposed. Firstly, a color channel transformation module is constructed, and learnable parameters are introduced to transform different color channels, enhancing the flexibility of the enhancement strategy. Then, an image enhancement module is employed to preprocess the input images. This module is jointly optimized with the object detection network using detection loss functions, thereby enabling the enhancement module to learn to generate representations that explicitly facilitate the subsequent detection task. Additionally, a selective self-supervised regression loss is proposed that uses both the original low-illumination images and the enhanced images as inputs to optimize the detection network. According to detection results, the enhancement module is further optimized through self-supervised regression to improve detection performance. Experimental results show that, compared with the baseline method, the mean average precision (mAP) metrics on the Exdark, M3FD, and LLVIP datasets are improved by 2.2%, 1.1%, and 0.2% respectively.

**Key words:** object detection; image enhancement; deep learning; joint optimization; self-supervision

\* 收稿日期: 2025-05-06; 修回日期: 2025-08-29  
项目基金: 国家自然科学基金资助项目 (62303433)  
通信作者: 朱佩佩 Email: zhupeipei0806@sina.com

## 0 引言

目标检测作为计算机视觉领域中一个重要的基础任务,旨在从图像中准确地识别目标类别和位置信息<sup>[1-3]</sup>,在自动驾驶<sup>[4-5]</sup>、环境监测<sup>[6]</sup>、国防安全<sup>[7]</sup>等领域发挥了重要作用。由于广泛的应用需求和软硬件技术的不断进步,基于深度学习的目标检测技术引起了学术界和工业界的广泛关注<sup>[8-13]</sup>,已经取得了长足的进步。然而,现有基于学习的目标检测算法主要在 COCO<sup>[14]</sup>、PASCAL VOC<sup>[15]</sup>等标准数据集上进行优化,当处理夜间、背光等低照度图像时,检测性能会大幅下降,进而影响决策系统的判断能力和决策准确性。

在此背景下,提升检测算法在低照度场景中的鲁棒性和泛化性具有重要的理论价值和广泛的实际应用意义。现有的低光增强网络例如 MBLLEN<sup>[16]</sup>、KIND<sup>[17]</sup>、Zero-DCE<sup>[18]</sup>等能够增强低照度图像,使其更符合人类观感,但是增强结果难以避免与实际高亮图像的域差异,简单地利用图像增强结果进行感知任务,并不能为低照度场景中的视觉感知任务带来最优增益。为应对该问题,部分研究者尝试在训练过程中将图像增强与目标检测网络进行联合优化:Sun 等人<sup>[19]</sup>提出的对抗学习范式,使增强后的图像更适合检测模型;Yin 等人<sup>[20]</sup>提出了一种基于 Laplace 变换的金字塔增强网络,用于低照度环境下的目标检测;Qin 等人<sup>[21]</sup>通过 Laplace 金字塔将输入图像分解为低频分量和高频分量分别进行处理,并引入了全局增强模块、跨层引导模块和细节增强模块,能够有效去除天气信息并保留目标的潜在特征;Hashmi 等人<sup>[22]</sup>提出了一种用于低光照条件下目标检测的特征增强方法,通过增强层次化特征来提升检测性能;Cui 等人<sup>[23]</sup>考虑了图像预处理引入的额外复杂度问题,提出了一种轻量级的图像增强网络,通过少量参数实现高效的图像增强。部分研究还探索了图像自适应的解决方案:IA-YOLO<sup>[24]</sup>和 GDIP<sup>[25]</sup>通过设计可微分的图像自适应处理模块,自适应调整图像对比度、白平衡,并进行去雾、平滑、锐化等操作以应对恶劣环境下的目标检测任务;ERUP-YOLO<sup>[26]</sup>将经典的图像处理滤波器简化为基于贝塞尔曲线的像素级滤波器和基于核的局部滤波器,并且不需要针对特定数据定制滤波器组合。这些方法使用检测损失联合优化图像自适应增强模块和目标检测网络,使处理后的图像更适用于检测任务感知。此外,MAET<sup>[27]</sup>和 DAINet<sup>[28]</sup>通过在低光合

成数据集上训练模型,分别利用多任务学习和域自适应的方式使网络能够从输入图像中提取光照不变信息,继而提升低光图像目标检测的性能。但是,这些方法通常依赖于专用的低光增强数据集或合成数据集,限制了其在实际场景中的适用性。Hong 等人<sup>[29]</sup>提出了一种学习光照不变特征的方法,通过光照不变的特征表示减少光照变化对检测性能的影响。

总体而言,现阶段针对低照度场景目标检测的优化方法虽然取得了显著的成果,但是未能充分考虑不同颜色通道间的差异。此外,现有大多数“增强-检测”算法使用增强图像进行检测任务,没能充分利用原始输入图像信息。为此,本文提出了一种基于颜色通道变换增强的低照度图像目标检测算法,引入可学习的参数对不同颜色通道进行调整,并充分利用增强图像与原始图像对检测网络进行优化,还提出了选择性自监督回归损失,保障增强模块对于检测任务的有效性,进一步提升了检测效果。

## 1 改进的 C2TEOD

### 1.1 整体框架

为了提升低照度图像的检测性能,本文提出了两个关键改进方案,显著提升了现有检测算法在低照度图像中的性能。第一个改进模块为颜色通道变换增强网络(Color Channel Transformation Enhancement Network, C2TEN)。不同于现有改进方案,该模块在进行图像增强前,引入了一个颜色通道转换步骤。进一步地,通过巧妙引入可学习参数,分别对输入图像的 r、g、b 3 个颜色通道进行调节。该模块能够有效提升模型对不同光照条件和场景的适应能力,使模型在处理复杂多变的低照度图像时具备更灵活的调整空间,从而为后续处理奠定坚实基础。第二个改进方案是选择性自监督回归损失,根据监测结果判断是否需要分别对原始图像和增强图像计算回归损失,充分确保了增强后的图像结果紧密贴合检测任务的内在需求,最大程度发挥增强图像对检测网络的助力作用。提出的改进方案效果显著,适应性强,易于集成到现有的先进目标检测方法中。

本文方法整体框图如图 1 所示。在训练阶段,模型首先通过颜色转换模块对输入图像  $x$  的 3 个颜色通道进行调节,然后输入增强网络强化图像信息表示;再将增强后的图像与原始图像共同输入至检

测网络得到预测结果,并基于这两组输入对应的检测损失共同优化增强网络与检测网络,使增强网络朝着更适合检测网络感知的方向优化;最后,提出选择性自监督回归损失,根据增强图像与原始图像的监测损失,判断是否利用回归损失优化图像增强网络。因此,本文方法的整体损失包括原始图像检测损失、增强图像检测损失和选择性回归损失,具体如下:

$$L_{total} = \alpha(L_{det}(x) + L_{det}(x^{en})) + (1-\alpha)L_{reg}^s \quad (1)$$

式中: $L_{det}(x)$ 为原始输入图像 $x$ 的检测损失; $L_{det}(x^{en})$ 为增强图像 $x^{en}$ 的检测损失; $L_{reg}^s$ 为选择性自监督回归损失; $\alpha \in (0 \sim 1)$ 为平衡系数。检测损失可定义为

$$L_{det} = \lambda_{cls} L_{cls} + \lambda_{box} L_{box} + \lambda_{obj} L_{obj} \quad (2)$$

式中: $L_{cls}$ 、 $L_{box}$ 和 $L_{obj}$ 分别是目标类别损失、位置损失和置信度损失; $\lambda_i$ 为不同损失的权重参数。




图 1 基于通道变换增强的低照度图像目标检测方法

在推理阶段,首先利用训练好的增强网络,对输入图像进行自适应增强,其输出结果更适用于检测网络感知。接着,将增强后的图像输入至检测网络,得到包含目标类别、位置及置信度的检测结果,实现对图像中目标的精确识别与定位。

### 1.2 颜色通道变换图像增强网络

如图 1 所示,本文提出的颜色通道变换图像增强网络(C2TEN)包含一个颜色转换模块和一个由卷积网络构成的图像增强网络,其中颜色通道变换模块的工作流程如图 2 所示。对于输入图像  $x \in \mathbb{R}^{3 \times H \times W}$ ,该模块为 r、g、b 3 个颜色通道分别赋予可学习的权重  $\omega_r$ 、 $\omega_g$ 、 $\omega_b$ ,通过广播机制将这些权重维度拓展至与图像空间维度相同的尺寸,确保与图像各通道数据匹配。随后,通过非线性运算,对图像各通道像素值进行加权。具体过程可表示为

$$O_k^{i,j} = I_k^{i,j} + \omega_k (I_k^{i,j} - I_k^{i,j^2}), k \in r, g, b \quad (3)$$

式中: $I_k^{i,j}$ 表示输入图像在颜色通道 $k$ 中 $i$ 行 $j$ 列的像素值。通过上述方法,可以针对性地对图像颜色特征进行调节,从而增强模型对不同光照条件和场

景的适应能力。




图 2 颜色通道变换模块工作流程

经颜色转换模块调整图像光照曲线后,将图像输入编解码形式的增强网络。其具体网络参数如表 1 所示,其中 $C$ 、 $K$ 、 $S$ 分别表示输出通道数、卷积核大小和卷积步长。

表 1 图像增强网络架构及具体参数

Layer	stage	Module
Layer1		Conv, $C = 32, K = 3, S = 1$ ReLU
Layer2	Encoder	Conv, $C = 64, K = 3, S = 2$ ReLU
Layer3		Conv, $C = 128, K = 3, S = 2$ ReLU
Layer4		Deconv, $C = 64, K = 3, S = 2$ Conv, $C = 64, K = 3, S = 1$ ReLU
Layer5	Decoder	Deconv, $C = 32, K = 3, S = 2$ Conv, $C = 32, K = 3, S = 1$ ReLU
Layer6		Conv, $C = 3, K = 3, S = 1$

对于输入图像,首先经过 3 层卷积网络提取多尺度图像特征,具体过程如下:

$$\begin{cases} f_{x_1}^e = \text{ReLU}(\text{Conv}_{3,1}(x^c)) \\ f_{x_2}^e = \text{ReLU}(\text{Conv}_{3,2}(f_{x_1}^e)) \\ f_{x_4}^e = \text{ReLU}(\text{Conv}_{3,2}(f_{x_2}^e)) \end{cases} \quad (4)$$

式中: $\text{Conv}_{k,s}(\cdot)$ 表示核为 $k$ ;步长为 $s$ 的卷积模块; $\text{ReLU}(\cdot)$ 表示 ReLU 激活函数; $f_{x_n}^e$ 表示编码的多尺度特征; $\times n$ 表示特征空间尺度降采样倍数。

然后,利用提取的多尺度特征 $f_{x_1}^e, f_{x_2}^e, f_{x_4}^e$ 进行解码,得到增强图像。具体地,首先利用反卷积对深层特征 $f_{x_4}^e$ 进行上采样,再与 $f_{x_2}^e$ 沿通道维度进行特征拼接,进一步通过卷积和 ReLU 激活函数提取融合特征并进行非线性变换。然后,重复上述过程,利用拼接后的特征 $f_{x_2}^e$ 经过反卷积进行上采样,再与浅层特征 $f_{x_1}^e$ 进行拼接。最后,通过一层卷积网络

融合特征信息并调整通道数,得到增强图像。上述过程可由公式表示为

$$\begin{cases} f_{x_2}^d = \text{ReLU}(\text{Conv}_{3,1}(\text{Cat}(\text{Deconv}(f_{x_4}^e), f_{x_2}^e)_c)) \\ f_{x_1}^d = \text{ReLU}(\text{Conv}_{3,1}(\text{Cat}(\text{Deconv}(f_{x_2}^e), f_{x_1}^e)_c)) \end{cases} \quad (5)$$

$$x_{en} = \text{Conv}_{3,1}(f_{x_1}^d) \quad (6)$$

式中: $\text{Cat}(\cdot)_c$ 表示沿通道维度进行特征拼接; $f_{x_n}^e$ 代表DCR模块的输出特征; $\text{Deconv}(\cdot)$ 指反卷积运算过程。

### 1.3 选择性自监督回归损失

实际应用场景中,成像环境较为复杂,增强网络无法保证增强结果始终都适用于检测任务。为此,在模型优化过程中,引入了选择性自监督回归损失。该损失在利用增强图像和原始图像优化检测网络时,依据两图像的检测结果判断是否计算回归损失,能够使图像增强网络更适用于检测任务,并且加速模型的收敛速度。具体地,如图1所示,利用增强图像与原始图像检测损失作为评判标准:若增强图像检测损失小于原始图像检测损失,则表明增强模型能够使检测效果更好;反之则表明增强图像的检测效果不如原始输入图像,仍需进一步优化。因此,本文提出的选择性自监督回归损失,在增强图像检测损失大于原始图像检测损失时,引入L1损失,利用原始图像作为自监督信号,进一步优化图像增强网络。该损失可表示为

$$L_{reg}^s = \begin{cases} |x^{en} - x|_1, & \text{if } L_{det}(x^{en}) > L_{det}(x) \\ 0, & \text{otherwise} \end{cases} \quad (7)$$

式中: $x^{en}$ 是增强图像; $L_{det}(x^{en})$ 和 $L_{det}(x)$ 分别表示增强图像和原始输入图像的检测损失。

## 2 实验与分析

### 2.1 数据集和评估指标

为了验证本方法的有效性,本文在Exdark数据集上进行了相关实验,使用平均精度均值(mean Average Precision, mAP)作为模型的评价指标。在模型效率方面,本文根据模型参数量和帧率(Frames Per Second, FPS)来评估模型复杂度。

ExDark<sup>[30]</sup>数据集是一个低光照环境下的目标检测数据集。该数据集包含7363幅亮度不同的夜间图像,涉及12种目标类别。为了评估模型在低光照条件下的性能并与现有方法进行对比,该数据集

的划分方式与MAET<sup>[21]</sup>保持一致,其中80%的图像用于训练,20%用于测试。

M3FD<sup>[31]</sup>数据集是一个全天候目标检测数据集,共包含4200张在黄昏及夜晚场景的可见光图像,标注了6种目标类别。随机选取了可见光图像中的3500张用于训练,700张用于测试。

LLVIP<sup>[32]</sup>数据集是一个行人检测数据集,包含15488张附带有行人标注的可见光图像,且这些图像大多在夜间环境拍摄。选取其中的12025张图像用于训练,剩余3463张图像用于测试。

### 2.2 实验配置和实施细则

本文实验系统采用Ubuntu 20.04。所有实验均基于PyTorch框架进行。GPU型号为GeForce RTX 3090,拥有24GB显存。此外,CPU型号为Intel(R)Core(TM)i7-11700。系统内存大小为64GB,采用DDR4版本。在基类模型训练阶段,本文使用在COCO数据集上预训练的YOLOv3网络进行优化。采用线性学习率,初始学习率为0.01,最后一轮下降到0.001。第一阶段训练时的批次大小设置为8,第二阶段训练批次大小设置为1。采用SGD优化器,其动量超参数设置为0.937,权重衰减超参数设置为0.0005,输入图像尺寸固定为640×640。

### 2.3 主流算法对比

为了验证本文方法的先进性,在Exdark数据集上对比了多种不同类型的低照度图像检测方法,包括MBLLEN<sup>[16]</sup>、KIND<sup>[17]</sup>、ZeroDCE<sup>[18]</sup>、SCI<sup>[33]</sup>4种亮度增强预处理方法,IAYOLO<sup>[24]</sup>、PEYOLO<sup>[20]</sup>、DEYOLO<sup>[21]</sup>、SCI\*<sup>[33]</sup>4种图像增强-检测联合优化方法,以及MAET<sup>[27]</sup>、DAINet<sup>[28]</sup>、YOLA<sup>[29]</sup>3种光照不变特征提取方法。为确保公平,上述对比方法均采用YOLOv3作为基础检测网络。

低亮度图像增强预处理方法先采用预训练的MBLLEN、KING、ZeroDCE、SCI对低照度图像进行增强后再进行目标检测。与此类方法的对比实验结果如表2所示,本文算法取得了78.7%的mAP指标,显著优于现有的低光照图像增强预处理方法。并且在涉及的12个类别中,该算法在10个类别上均取得了最优的检测结果,显示出本文算法优秀的稳定性和可靠性。此外,在人、小汽车这两类重要目标的检测精度提升明显,相比次优算法,mAP指标分别提高了1.9%和0.9%。

表 2 本文算法与低亮度图像增强预处理方法在 Exdark 数据集上的对比结果

方法	AP/%												mAP/%
	自行车	小船	瓶子	公交车	小汽车	猫	椅子	杯子	狗	摩托车	人	桌子	
KIND <sup>[17]</sup>	79.4	74.6	77.0	<b>92.7</b>	84.2	71.1	66.5	73.4	78.2	75.4	79.6	55.5	75.7
MBLLEN <sup>[16]</sup>	82.6	<u>77.1</u>	81.0	92.5	83.9	71.5	68.4	74.3	76.9	<b>78.2</b>	80.1	<u>57.7</u>	77.0
ZeroDCE <sup>[18]</sup>	<u>82.9</u>	73.1	78.9	91.0	<u>85.3</u>	<b>76.1</b>	66.9	<u>75.1</u>	79.9	77.6	<u>80.5</u>	57.3	<u>77.1</u>
SCI <sup>[33]</sup>	82.7	74.6	77.5	91.0	84.1	73.0	67.8	75.0	<u>79.6</u>	77.0	79.3	57.1	76.6
C2TEOD	<b>83.3</b>	<b>77.9</b>	<b>81.1</b>	<b>92.7</b>	<b>86.2</b>	<u>73.7</u>	<b>70.8</b>	<b>78.2</b>	<b>81.0</b>	<u>77.1</u>	<b>82.4</b>	<b>59.8</b>	<b>78.7</b>

对于图像增强与检测联合优化方法, 选择了 IAYOLO<sup>[24]</sup>、PEYOLO<sup>[20]</sup>、DEYOLO<sup>[21]</sup> 和 SCI\*<sup>[33]</sup> 4 种优化方法作为对比算法。SCI\* 引入预训练的 SCI 增强网络与检测网络联合优化, 此类方法均使用检测损失进行端到端的优化, 对比结果如表 3 所示, 可见与当前现有的图像增强与检测联合

优化算法相比, 本文所提出的算法取得了最高的平均精度。相比于次优的 PEYOLO, mAP 指标提高了 0.7%。且在涉及到的 12 个类别目标中, 有 7 个最优类目标均取得最优检测效果, 表明本文算法在低亮度场景中目标检测效果优于联合优化算法。

表 3 本文算法与图像增强和检测联合优化方法在 Exdark 数据集上的对比结果

方法	AP/%												mAP/%
	自行车	小船	瓶子	公交车	小汽车	猫	椅子	杯子	狗	摩托车	人	桌子	
IAYOLO <sup>[24]</sup>	<u>84.3</u>	77.4	<u>80.4</u>	90.7	84.5	<u>73.7</u>	68.9	75.4	80.7	<b>79.4</b>	81.1	57.0	77.8
PEYOLO <sup>[20]</sup>	<b>84.7</b>	<u>79.2</u>	79.3	92.5	83.9	71.5	<b>71.7</b>	79.7	79.7	<u>77.3</u>	81.8	55.3	<u>78.0</u>
DEYOLO <sup>[21]</sup>	80.4	<b>79.7</b>	77.9	<u>91.2</u>	82.7	72.8	69.9	<u>80.1</u>	77.2	76.7	<u>82.0</u>	<u>57.2</u>	77.3
SCI* <sup>[33]</sup>	83.9	75.1	79.4	90.8	<u>85.2</u>	<b>75.0</b>	69.6	76.6	<u>80.8</u>	76.0	80.5	<u>57.2</u>	77.4
C2TEOD	83.3	77.9	<b>81.1</b>	<b>92.7</b>	<b>86.2</b>	<u>73.7</u>	<u>70.8</u>	<b>78.2</b>	<b>81.0</b>	77.1	<b>82.4</b>	<b>59.8</b>	<b>78.7</b>

此外, 还对比了 MAET<sup>[27]</sup>、DAINet<sup>[28]</sup> 和 YOLA<sup>[29]</sup> 3 种通过提取光照不变特征优化的低照度图像目标检测方法。其中, MAET 采用多任务联合优化方案学习光照不变特征, DAINet 通过域自适应方法提取光照不变特征, YOLA 则引入了一个额外的光照不变损失。如表 4 所示, 与这类算法相比,

提出的 C2TEOD 在检测效果上具备一定的优势, 相比次优的 DAINet 提升了 0.4% 的 mAP, 并且对于不同类别的目标实现了更为均衡的检测效果。需要注意的是, 这类算法通常需要在合成图像上进行训练, 而本文算法直接在原始低照度图像上进行优化, 避免了复杂的数据转换流程, 更符合实际场景需求。

表 4 本文算法与光照不变特征提取方法在 Exdark 数据集上的对比结果

方法	AP/%												mAP/%
	自行车	船	瓶子	公交车	小汽车	猫	椅子	杯子	狗	摩托车	人	桌子	
MAET <sup>[27]</sup>	83.1	<u>78.5</u>	75.6	<u>92.9</u>	73.1	73.4	<u>71.3</u>	<u>79.0</u>	79.8	<b>77.2</b>	<u>81.1</u>	57.0	77.7
DAINet <sup>[28]</sup>	<u>83.8</u>	75.8	75.1	<b>94.2</b>	84.1	<b>74.9</b>	<b>73.1</b>	<b>79.2</b>	<b>82.2</b>	76.4	80.7	<b>59.8</b>	<u>78.3</u>
YOLA <sup>[29]</sup>	<b>84.8</b>	<u>78.1</u>	<u>80.0</u>	92.0	<u>85.4</u>	<u>73.8</u>	69.6	76.7	78.9	76.8	79.9	58.4	77.9
C2TEOD	83.3	77.9	<b>81.1</b>	92.7	<b>86.2</b>	73.7	70.8	78.2	<u>81.0</u>	<u>77.1</u>	<b>82.4</b>	<b>59.8</b>	<b>78.7</b>

为了更直观地说明本文算法的优势, 从上述 3 种改进方案中分别选取了 SCI 作为图像预处理方法、IAYOLO 作为图像增强-检测联合优化方法、YOLA 作为光照不变特征提取方法, 与基线网络 YOLOv3 和本文算法进行检测结果可视化对比。如图 3 所示, 相较于 YOLOv3 和上述 3 种对比方

法, 本文算法在低照度图像中能够更准确地检测出自汽车和行人等目标, 并且显著减少漏检和误检的情况。此外, 还准确检测出 Ground Truth 中部分没有标注的目标, 说明了检测结果的可靠性。上述结果显示了本文算法在低照度场景中的有效性。



图 3 在 Exdark 数据集上的可视化检测结果

图 4 展示了利用 HiResCAM<sup>[34]</sup> 对所提算法的解码特征进行热力图可视化的结果,可以看出,检测模型的关注焦点主要聚焦于目标区域,并且能够敏锐捕捉到夜间等低照度环境中较为隐蔽且不易察觉的目标,验证了本文所提算法在低照度图像上的有效性。



图 4 热力图可视化结果

在模型复杂度方面,表 5 对基础检测网络 YOLOv3、亮度增强预处理算法 ZeroDCE 和 SCI、联合优化算法 IAYOLO、光照不变特征提取算法 YOLA 以及本文提出的 C2TEOD 算法进行了对比分析。在模型层面评估了参数量 (Params) 与计算量 (GFLOPs),并通过帧率 (FPS) 评估推理速度。可以

看出,相比于 YOLOv3,以上方法在模型参数量上都有少量的增加。ZeroDCE 的预处理策略带来 0.6% 的 mAP 提升,但计算量增加了 32.44GFLOPs。SCI 采用轻量化图像增强网络,计算量仅增加 0.22GFLOPs,推理速度下降约 4 frame/s,但 mAP 仅提高了 0.1%。IAYOLO 与 YOLA 虽在参数量上变化不大,但由于需要执行复杂的图像滤波或曲线调整操作,FPS 下降更为明显。相比之下,本文提出的 C2TEOD 在引入图像预处理模块的同时,虽使计算量有所增加,但推理速度仍优于 IAYOLO 和 YOLA,并在 mAP 指标上较对比算法实现了更大幅度的提升。与表现次优的 YOLA 相比,mAP 仍有 0.8% 的提升。总体而言,所提算法在检测精度与运行速度之间实现了更优的平衡。

表 5 复杂度及性能对比

Method	Params/ $10^6$	GFLOPs	FPS	mAP/%
YOLOv3	61.556 7	77.36	103	76.5
ZeroDCE <sup>[18]</sup>	61.599 2	109.80		77.1
SCI <sup>[33]</sup>	61.557 0	77.58	99	76.6
IAYOLO <sup>[24]</sup>	61.721 6	77.40	57	77.8
YOLA <sup>[29]</sup>	61.565 3	80.98	68	77.9
C2TEOD	61.835 3	112.04	72	78.7

在模型泛化性方面,如图 5 所示,当以 YOLOv3 作为基准检测网络时,在 Exdark、M3FD 和 LLVIP 3 个数据集的 mAP 指标分别提升 2.2%、1.1% 和 0.2%,证明了所提方法的泛化能力。




图 5 本文算法在不同数据集上的效果

本文提出算法具备较强的可扩展性,并不局限于单一检测模型。如图 6 所示,在不同版本的 YOLO 系列算法上本文方法都能够有效提升在 Exdark 数据集上的检测效果,在 YOLOv3、YOLOv5s、YOLOv7 模型和 YOLOv9 的 Gelan-s 模型上分别使 mAP 指标提升了 2.2%、1.7%、1.3% 和 0.5%,表明本文算法在不同检测器上都能够提升低照度图像的检测效果。




图 6 本文算法在不同基线网络上的效果

### 2.4 消融实验

为评估本文提出方法和模块的有效性,本节在 Exdark 数据集上对本文所提出的颜色通道变换图像增强网络和选择性自监督回归损失进行了细致的消融实验。如表 6 所示,通过逐个引入各个改进方案,验证各改进点的作用,其中, IEN (Image Enhancement Network) 为图像增强网络, CT (Color Transform) 指颜色通道转换模块。 IEN 与 CT 共同构成 C2TEN 模块。  $L_{reg}^s$  指选择性回归损失。具体地, YOLOv3 基线检测网络取得了 76.5% 的 mAP 指标。引入颜色通道转换模块 (CT) 调节 3 个颜色通道的像素值,可使 mAP 提升 0.4%。单独利用图像增强网络 ( IEN) 对输入图像进行自适应增强,能带来 0.9% 的 mAP 指标提升,但会引入额外的模型参数,并导致检测效率速度下降。同时引入上述两个模块,构成颜色通道变换图像增强网络, mAP 进一步提升至 77.9%。最后,在训练过程中引入选择性自监督回归损失,能够显著提升低照度图像的检测准确率, mAP 达到 78.7%。上述实验过程充分说明了 3 个改进点的有效性。

表 6 消融实验

Baseline	IEN	CT	$L_{reg}^s$	mAP/%	Params/ $10^6$	FPS
YOLOv3	×	×	×	76.5	61.56	103
	×	√	×	76.9	61.56	102
	√	×	×	77.4	61.84	79
	√	√	×	77.9	61.84	78
	√	√	√	78.7	61.84	79

在模型复杂度方面,由于引入了 C2TEN 进行图像自适应增强,导致参数量提升  $2.8 \times 10^5$ ,约占总参数量 ( $6.184 \times 10^7$ ) 的 0.4%。推理速度降至 79 frame/s,尽管相比基线网络有所下降,但仍能满足实时目标检测需求。

表 7 评估了损失函数平衡系数  $\alpha$  变化对模型性能的影响。当  $\alpha=0.2$  时,检测性能最优;当  $\alpha>0.2$  时,性能呈下降趋势。

表 7 损失权重消融

$\alpha$	mAP/%	$\alpha$	mAP/%
0.1	78.28	0.4	78.32
0.2	78.7	0.6	78.45
0.3	78.23	0.8	78.09

### 3 结束语

图像自适应增强模块是低照度图像目标检测的典型优化方案之一。本文提出了一种基于颜色通道变换增强的低照度图像目标检测算法,其中,提出的 C2TEN 引入可学习的参数对输入图像的不同颜色通道分别进行调整,然后提出了选择性自监督回归损失,约束增强模块使其输出结果更有利于检测网络感知。两个改进都可以很容易地与现有检测网络相结合,增强在低照度场景的检测能力。在 Exdark 数据集上的实验结果验证了两个改进方案的有效性,取得了 78.7% 的 mAP 指标,证明了本文方法优于现有的低照度图像检测算法。在 M3FD 和 LLVIP 数据集上分别取得了 90.2% 和 92.6% 的 mAP 指标,证明了本文方法的泛化性。

然而,图像增强预处理模块仍会导致检测效率下降,未来工作可进一步研究蒸馏或网络剪枝等技术构造更轻量级的图像预处理方案。

### 参考文献:

- [1] 官文彬,吴晓红,陈洪刚,等. 基于蒸馏响应的类增量少样本遥感目标检测研究[J]. 新一代信息技术, 2023,6(21):1-7.
- [2] 郭振江,何小海,吴晓红,等. 改进 YOLOv7 的无边界不连续旋转检测算法[J]. 新一代信息技术, 2023,6(20):1-12.
- [3] WANG X F, LIU X, YANG H, et al. Degradation modeling for restoration-enhanced object detection in adverse weather scenes [J]. IEEE Transactions on Intelligent Vehicles, 2025, 10(3):2064-2079.
- [4] 曹家乐,李亚利,孙汉卿,等. 基于深度学习的视觉目标检测技术综述[J]. 中国图象图形学报, 2022, 27(6):1697-1722.
- [5] LI J L, XU R S, MA J, et al. Domain adaptive object detection for autonomous driving under foggy weather [C]//2023 IEEE/CVF Winter Conference on Applications of Computer Vision. Waikoloa:IEEE, 2023:612-622.
- [6] TANG W Y, HE F, BASHIR A K, et al. A remote sensing image rotation object detection approach for real-time environmental monitoring [J]. Sustainable Energy Technologies and Assessments, 2023, 57:1-8.
- [7] LI R H, SHEN Y. YOLOS-R-IST: a deep learning method for small target detection in infrared remote sensing images based on super-resolution and YOLO [J]. Signal Processing, 2023, 208:1-12.
- [8] 张阳婷,黄德启,王东伟,等. 基于深度学习的目标检测算法研究与应用综述[J]. 计算机工程与应用, 2023, 59(18):1-13.

- [ 9 ] 聂光涛,黄华. 光学遥感图像目标检测算法综述[J]. 自动化学报,2021,47(8):1749-1768.
- [ 10 ] 邵延华,张铎,楚红雨,等. 基于深度学习的 YOLO 目标检测综述[J]. 电子与信息学报,2022,44(10):3697-3708.
- [ 11 ] 何智杰,肖玮,刘南清,等. 基于深度半监督学习的目标检测技术综述[J]. 电讯技术,2025,65(3):484-494.
- [ 12 ] 施克权,李祺,隋皓,等. IEMAyoloViT: 基于改进 YOLOv8 的水下目标检测算法[J]. 电讯技术,2025,65(1):54-62.
- [ 13 ] HUANG X C, TENG Q Z, YANG H, et al. CRKD-YOLO: cross-resolution knowledge distillation for low-resolution remote sensing image object detection [ J ]. IEEE Transactions on Instrumentation and Measurement, 2025, 74:1-17.
- [ 14 ] LIN T Y, MAIRE M, BELONGIE S, et al. Microsoft COCO: common objects in context [ C ] // 2014 European Conference on Computer Vision. Cham: Springer, 2014: 740-755.
- [ 15 ] HOIEM D, DIVVALA S K, JAMES H, et al. Pascal VOC 2008 challenge [ J ]. World Literature Today, 2009, 24(1):1-4.
- [ 16 ] LV F F, LU F, WU J H, et al. MBLLEN: low-light image/video enhancement using CNNs [ C ] // British Machine Vision Conference. Newcastle: ACM, 2018: 220-229.
- [ 17 ] ZHANG Y H, ZHANG J W, GUO X J. Kindling the darkness: a practical low-light image enhancer [ C ] // The 27th ACM International Conference on Multimedia. Nice: IEEE, 2019: 1632-1640.
- [ 18 ] GUO C L, LI C Y, GUO J C, et al. Zero-reference deep curve estimation for low-light image enhancement [ C ] // 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020: 1777-1786.
- [ 19 ] SUN S Q, REN W Q, WANG T, et al. Rethinking image restoration for object detection [ C ] // The 36th International Conference on Neural Information Processing Systems. New Orleans: IEEE, 2022: 4461-4474.
- [ 20 ] YIN X C, YU Z D, FEI Z T, et al. PE-YOLO: pyramid enhancement network for Dark object detection [ C ] // Artificial Neural Networks and Machine Learning. Cham: Springer, 2023: 163-174.
- [ 21 ] QIN Q P, CHANG K, HUANG M Y, et al. DENet: detection-driven enhancement network for object detection under adverse weather conditions [ C ] // 2022 Asian Conference on Computer Vision. Cham: Springer, 2023: 491-507.
- [ 22 ] HASHMI K A, KALLEMPUDI G, STRICKER D, et al. FeatEnHancer: enhancing hierarchical features for object detection and beyond under low-light vision [ C ] // 2023 IEEE/CVF International Conference on Computer Vision. Paris: IEEE, 2024: 6702-6712.
- [ 23 ] CUI Z T, LI K C, GU L, et al. You only need 90K parameters to adapt light: a light weight transformer for image enhancement and exposure correction [ EB/OL ]. [ 2025-05-01 ]. <https://arxiv.org/abs/2205.14871>.
- [ 24 ] LIU W Y, REN G F, YU R S, et al. Image-adaptive YOLO for object detection in adverse weather conditions [ EB/OL ]. [ 2025-05-01 ]. <https://doi.org/10.1609/aaai.v36i2.20072>.
- [ 25 ] KALWAR S, PATEL D, AANEGOLA A, et al. GDIP: gated differentiable image processing for object detection in adverse conditions [ C ] // 2023 IEEE International Conference on Robotics and Automation. London: IEEE, 2023: 7083-7089.
- [ 26 ] OGINO Y, SHOJI Y, TOIZUMI T, et al. ERUP-YOLO: enhancing object detection robustness for adverse weather condition by unified image-adaptive processing [ C ] // 2025 IEEE/CVF Winter Conference on Applications of Computer Vision. Tucson: IEEE, 2025: 8597-8605.
- [ 27 ] CUI Z T, QI G J, GU L, et al. Multitask AET with orthogonal tangent regularity for dark object detection [ C ] // 2021 IEEE/CVF International Conference on Computer Vision. Montreal: IEEE, 2022: 2533-2542.
- [ 28 ] DU Z P, SHIT M, DENG J K. Boosting object detection with zero-shot day-night domain adaptation [ C ] // 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2024: 12666-12676.
- [ 29 ] HONG M B, CHENG S, HUANG H B, et al. You only look around: learning illumination invariant feature for low-light object detection [ EB/OL ]. [ 2025-05-01 ]. <https://arxiv.org/abs/2410.18398>.
- [ 30 ] LOH Y P, CHAN C S. Getting to know low-light images with the Exclusively Dark dataset [ J ]. Computer Vision and Image Understanding, 2019, 178: 30-42.
- [ 31 ] LIU J Y, FAN X, HUANG Z B, et al. Target-aware dual adversarial learning and a multi-scenario multi-modality benchmark to fuse infrared and visible for object detection [ C ] // 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans: IEEE, 2022: 5792-5801.
- [ 32 ] JIA X Y, ZHU C, LI M Z, et al. LLVIP: a visible-infrared paired dataset for low-light vision [ C ] // 2021 IEEE/CVF International Conference on Computer Vision Workshops. Montreal: IEEE, 2021: 3489-3497.
- [ 33 ] MA L, MA T Y, LIU R S, et al. Toward fast, flexible, and robust low-light image enhancement [ C ] // 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans: IEEE, 2022: 5627-5636.
- [ 34 ] DRAELOS R L, CARIN L. Use HiResCAM instead of Grad-CAM for faithful explanations of convolutional neural networks [ EB/OL ]. ( 2020-11-17 ) [ 2025-05-01 ]. <https://arxiv.org/abs/2011.08891>.

#### 作者简介:

张敏 女, 1996 年生于四川广元, 2021 年获硕士学位, 现为工程师, 主要研究方向为图像处理、深度学习。

乔文昇 男, 1969 年生于贵州毕节, 1990 年获学士学位, 现为研究员, 主要研究方向为航空电子系统。

朱佩佩 女, 1990 年生于湖北荆门, 2019 年获博士学位, 现为高级工程师, 主要研究方向为图像目标检测、多源数据融合。

朱思翰 男, 1996 年生于四川乐山, 2024 年获博士学位, 现为工程师, 主要研究方向为图像处理、深度学习和迁移学习。

詹雨飞 女, 1999 年生于安徽黄山, 2024 年获硕士学位, 现为助理工程师, 主要研究方向为目标检测、深度学习。

黄晓晨 男, 2000 年生于河南信阳, 2025 年获硕士学位, 现为博士研究生, 主要研究方向为图像处理、目标检测。

陈洪刚 男, 1991 年生于四川达州, 2019 年获博士学位, 现为副研究员、博士生导师, 主要研究方向为图像/视频处理、计算机视觉。