

基于暗光环境的实时目标检测算法研究与应用

葛岩松, 付东翔

上海理工大学光电信息与计算机工程学院, 上海

收稿日期: 2025年7月25日; 录用日期: 2025年8月17日; 发布日期: 2025年8月26日

摘要

为了提升视觉任务在复杂暗光环境中的鲁棒性, 并满足边缘计算平台对实时目标检测的需求, 本文提出了一种改进的轻量化暗光图像处理网络(RPC-YOLO)。该网络前端采用基于Retinexformer改进的RetinexIGTNet对暗光图像进行快速处理, 并结合YOLOv5n实现高效的端到端目标检测。此外, 模型引入部分卷积(C3-fasterblock)减少计算冗余, 跳过无用区域, 显著降低参数量并提升推理速度。同时, 设计级联注意力机制(CGA)增强特征提取精度和计算效率。实验表明, 改进后的模型在公开数据集上的mAP值较原YOLOv5n提升了23%, 参数量减少12万, 真实场景检测速度(FPS)达到44.65, 满足边缘计算平台的实时性需求。该模型为暗光环境下的边缘计算任务(如视觉引导的机械臂抓取)提供了更高效的解决方案。

关键词

暗光图像增强, 机器视觉, 边缘计算平台

Research and Application of Real-Time Object Detection Algorithm Based on Low-Light Environments

Yansong Ge, Dongxiang Fu

School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai

Received: Jul. 25th, 2025; accepted: Aug. 17th, 2025; published: Aug. 26th, 2025

文章引用: 葛岩松, 付东翔. 基于暗光环境的实时目标检测算法研究与应用[J]. 建模与仿真, 2025, 14(8): 286-296.
DOI: 10.12677/mos.2025.148567

Abstract

In order to enhance the robustness of visual tasks in complex low-light environments and enable to enhance the robustness of visual tasks in complex low-light environments and meet the real-time object detection requirements of edge computing platforms, this paper proposes an improved light-weight low-light image processing network (RPC-YOLO). The front end of the network uses the RetinexIGTNet, which is based on improvements to the Retinexformer, to quickly process low-light images and combines with YOLOv5n to achieve efficient end-to-end object detection. In addition, the model introduces partial convolution (C3-fasterblock) to reduce computational redundancy by skipping irrelevant regions, significantly reducing the number of parameters and improving inference speed. Meanwhile, a cascaded group attention mechanism (CGA) is designed to enhance the precision and computational efficiency of feature extraction. Experiments show that the improved model has increased the mAP value on public datasets by 23% compared with the original YOLOv5n, reduced the number of parameters by 120,000, and achieved a detection speed (FPS) of 44.65 in real scenes, meeting the real-time requirements of edge computing platforms. This model provides a more efficient solution for edge computing tasks in low-light environments (such as visually guided robotic arm grasping).

Keywords

Low-Light Image Enhancement, Machine Vision, Edge Computing Platform

Copyright © 2025 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

暗光目标检测在低光环境下应用受限, 因为光照不足和边缘平台算力受限导致目标识别精度下降, 影响实时性和鲁棒性。虽然图像增强算法可用于提升暗光检测性能, 但现有方法如直方图均衡化存在局限, 如局部失真、伪影生成、噪声放大和鲁棒性不足等问题, 限制了其普适性和实际应用价值。

随着深度学习技术的发展, Lore 等人[1]首次将自编码器引入低光图像增强网络, 奠定了深度模型在低光增强任务中的理论基础。Feng 等人[2]提出的 MVP-Net 基于 RAW 数据实现了出色的暗光图像复原, 但 RAW 图像的高存储和处理成本限制了其在边缘设备和工业环境中的应用。

随后, 基于卷积神经网络(CNN)的增强方法分为两类: 第一类直接使用 CNN 学习低光到正常光图像的映射关系, 但忽略了人类视觉系统的色彩特性, 缺乏可解释性和稳健性, 实际应用受限; 第二类基于 Retinex 理论, 采用分阶段训练框架[3]-[5], 通过多路 CNN 进行图像分解、去噪和亮度校正, 但训练过程复杂, 时间开销大。

近年来, Transformer 模型为上述问题提供了新思路。Cai 等人[6]结合 Retinex 理论和 Transformer 提出了 Retinexformer 模型, 其性能优于 PE-YOLO [7]和 SCINet [8], 但侧重于视觉质量提升, 与人眼关注点存在差异, 且模型复杂度高、参数量大, 对算力要求苛刻, 在边缘计算平台等高实时性任务中存在延迟高、计算负担重的问题。

针对这些问题, 本文提出了一种改进的端到端网络 RPC-YOLO, 针对边缘设备的实时性需求, 对网络进行了轻量化、提高检测效率和适配机器视觉特性的改进。改进后的模型在 mAP 上提升了 23%, 参数

量减少 12 万, 真实场景检测速度 FPS 达到 44.65, 满足边缘设备的实时性需求。

a) 提出了一种轻量化且实时性强的 RPC-YOLO 网络模型, 专门用于暗光环境下机械臂的抓取任务。

b) 将传统 Retinexformer 轻量化为 RetinexIGTNet, 用 1×1 卷积层替换全连接层, 并与 YOLOv5n 融合, 构建单阶段端到端网络, 既保留暗光增强特性, 又解决了多阶段处理的高计算量和时间成本问题, 适合在边缘计算平台上部署以满足实时任务需求。

c) 用多阶段、多样化的部分卷积 C3_Fasterblock 替换原模型中的 C3 残差卷积, 通过在不同通道间选择性卷积并传递特征, 同时在不同网络深度使用不同大小的卷积, 减少计算冗余并提高模型效率。

d) 引入级联注意力机制(CGA), 通过分组特征并利用多通道提取特征后进行融合, 增强模型对目标区域的特征表达和关注, 从而提高检测精度。

2. 相关概念

2.1. 边缘计算平台

边缘计算平台[9]是一种在靠近数据源或用户终端的网络边缘侧进行计算、存储和网络功能部署的架构。它打破了传统云计算中数据必须传输到遥远数据中心处理的模式, 使数据在产生源头附近就能被及时处理。

尽管边缘计算平台的算力相对有限, 难以应对大规模复杂任务, 但其在实时目标检测等任务中应用广泛。例如, 在无人机搜救场景中, 通过部署小型、精准且实时性强的模型, 可快速检测幸存者并发送位置信息; 在工业自动化中, 小型、精准的 AI 模型可快速处理传感器数据, 实现高效抓取动作, 保障生产流程顺畅。因此, 边缘计算平台通过适配小而精的模型, 仍能在特定场景中发挥重要作用。

2.2. 目标检测

目标检测技术从早期依赖手工特征(如 HOG 和 SIFT)的传统方法发展到基于卷积神经网络(CNN)的模型, 如 R-CNN [10]、Fast R-CNN [11]和 Faster R-CNN [12], 检测精度和效率不断提升。近年来, 单阶段检测器如 YOLO 系列和 SSD [13]逐渐成为主流, 特别是 YOLOv5 [14]引入轻量化架构和多种新颖的训练策略, 显著提升了检测速度和模型适应性。然而, 在暗光环境下, 大多数目标检测模型性能大幅下降, 难以满足实际部署需求。为此, 研究者提出了多种改进方法, 如 PE-YOLO 通过物理先验与数据驱动结合提升暗光检测性能; SCINet 通过光照增强模块与深层特征提取网络提升检测精度; IAT [15]采用 Transformer 结构与光照自适应模块保证模型稳健性; Retinexformer 通过照明先验估计和损坏修复模块实现优异表现。但这些方法存在参数量大、实时性差等问题, 限制了在边缘设备和实时任务中的应用。因此, 本文提出了 RPC-YOLO, 针对这些问题进行了全面优化。

3. 本文方法

3.1. 联合暗光增强检测网络 RPC-YOLO

在实际环境中, 机械臂抓取常受暗光等复杂光照条件影响, 导致物体特征识别出现偏差或失败。为此, 本文提出了一种联合增强检测框架(RPC-YOLO), 由改进的暗光增强模型 RetinexIGTNet 和基于 YOLOv5n 的检测模型组成。如图 1 所示, 输入 640×640 的 RGB 图像后, 先经 RetinexIGTNet 模块进行亮度调整、对比度增强和去噪处理, 输出改善后的清晰图像供检测网络使用。随后, 图像进入检测网络的 Backbone 和 Neck 层, 引入部分卷积(PCConv)和级联注意力机制(CGA), 优化特征提取与融合。RetinexIGTNet 提升了暗光图像质量, 解决了原模块计算量大、推理慢的问题, RPC-YOLO 实现了暗光增强与目标检测的高效协同, 为复杂光照环境下的边缘设备任务提供了可靠解决方案。

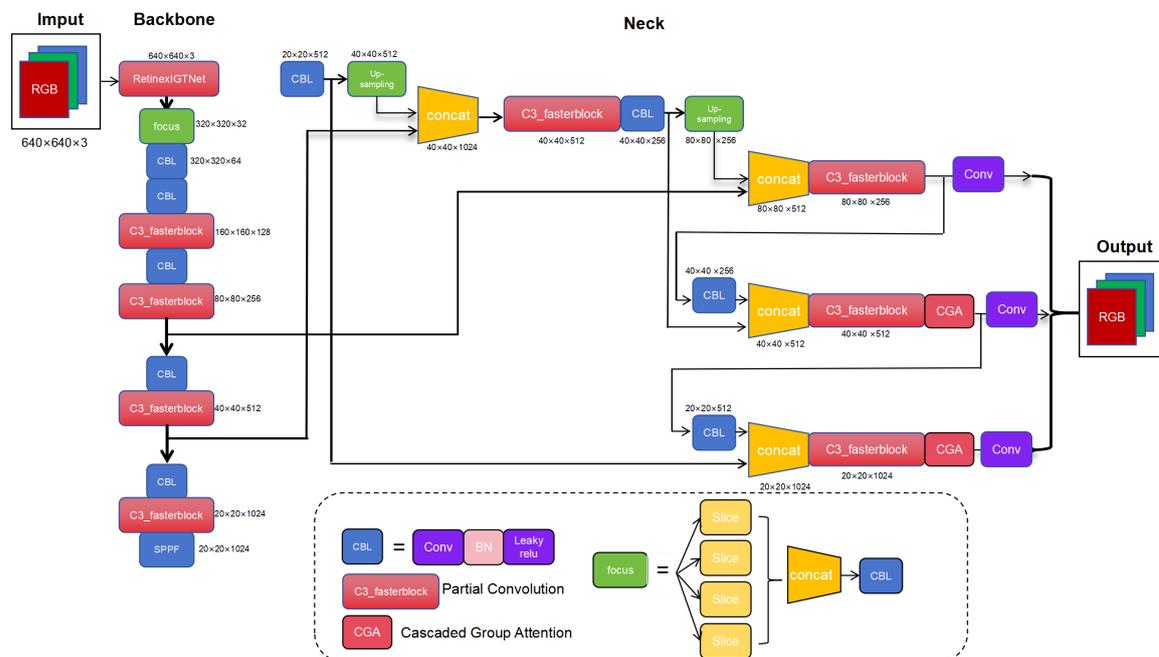


Figure 1. The network architecture of RPC-YOLO
图 1. RPC-YOLO 网络结构图

3.2. 暗光增强模块 RetinexIGTNet

RetinexIGTNet 基于单阶段 Retinex 框架(ORF)。ORF 由一个光照估计器和一个损坏修复器组成。RetinexIGTNet 的特点在于设计了一个光照引导 Transformer (IGT)作为损坏修复器的核心组件。IGT 的基本单元是光照引导注意力块(IGAB)，其中包含两层归一化(LN)、轻量化特征提取模块(IG-LFE)以及前馈网络(FFN)。整体结构如图 2。

One-stage Retinex-based Framework 根据 Retinex 原理，低光图像 $I \in \mathbb{R}^{H \times W \times 3}$ 可以分解为反射率图像 $R \in \mathbb{R}^{H \times W \times 3}$ 和照明映射 $L \in \mathbb{R}^{H \times W}$ ，表示为：

$$I = R \odot L \quad (1)$$

其中 \odot 表示逐元素乘法。该 Retinex 模型假设 I 无损坏，但这与真实的欠曝光场景不一致。因为其一：暗光场景中的高 ISO 值(感光度的标准)和长曝光时间不可避免地引入噪声和伪影；其二：图像增强过程会放大这些噪声和伪影，同时可能导致欠曝光或过曝光以及颜色失真。为了更准确地描述这些损坏，通过为 R 和 L 分别引入扰动项，对公式(1)进行重新定义：

$$I = (R + \hat{R}) \odot (L + \hat{L}) = R \odot L + R \odot \hat{L} + \hat{R} \odot (L + \hat{L}) \quad (2)$$

其中 $\hat{R} \in \mathbb{R}^{H \times W \times 3}$ 和 $\hat{L} \in \mathbb{R}^{H \times W}$ 分别表示反射和光照的扰动项。我们将 R 视为一副良好曝光的图像。为了增强 I ，通过逐元素乘法将方程(2)两侧与光照增强图 \bar{L} 相乘，使得 $\bar{L} \odot L = 1$ ，得到：

$$I \odot \bar{L} = R + R \odot (\hat{L} \odot \bar{L}) + (\hat{R} \odot (L + \hat{L})) \odot \bar{L} \quad (3)$$

其中 $\hat{R} \odot (L + \hat{L})$ 表示隐藏在暗场景中的噪声和伪影，被 \bar{L} 放大；而 $R \odot (\hat{L} \odot \bar{L})$ 表示增强过程中引起的欠曝光、过曝光和颜色失真。将 \bar{L} 设置为三通道 RGB 张量而不是单通道，以提高其在 RGB 通道间非线性模拟方面的表现能力，从而增强颜色效果。最终通过公式(3)中的 \bar{L} 完成对 I 的增强。

IGT: IGT 采用三尺度 U 型结构作为损坏修复模块，其输入使增强后的图像 I_{lu} 在下采样分支中图像

先通过一个 3×3 卷积(conv3 \times 3)、一个光照引导注意力块(IGAB)、一个步幅为 4 的卷积层(conv4 \times 4)进行特征降维, 然后经过两个 IGAB 块, 再通过一个步幅为 4 的卷积层生成层级特征 $F_i \in \mathbb{R}^{\frac{H}{2^i} \times \frac{W}{2^i} \times 2^i C}$ ($i=0, 1, 2$)。在最低层特征 F_2 中, 还会通过两个 IGAB 块进行深度特征提取。随后, 上采样分支采用对称结构, 将特征逐步放大, 并使用步幅为 2 的反卷积(deconv2 \times 2)进行上采样。跳跃连接(Skip Connection)用于缓解下采样时信息丢失。上采样分支最终输出一个残差图像 I_{re} , 然后与输入图像 I_{lu} 相加, 得到最终增强后的图像 $I_{en} = I_{lu} + I_{re}$ 。

IG-LFE: IG-LFE 的工作流程如下: 输入特征图按通道细分后, 经过多层 1×1 卷积进行特征提取。第一层实现通道混合和初步特征提取, 第二层增强非线性表达能力, 第三层完成特征融合与调整, 用于计算区域相似性和重要性。同时, 光照特征图通过 1×1 卷积提取特征并与值特征结合, 帮助模型识别光照不足区域并提升权重。最终, 整合后的特征输出用于恢复图像, 改善暗部细节, 减少噪声和伪影。通过单独处理特征图区域, 模型保留了空间结构信息, 避免模糊或失真, 保持图像自然感; 光照特征则引导模型更准确地识别暗光环境下物体的形状和结构。改进后的模型在确保图像空间结构信息的同时, 显著降低了计算量。

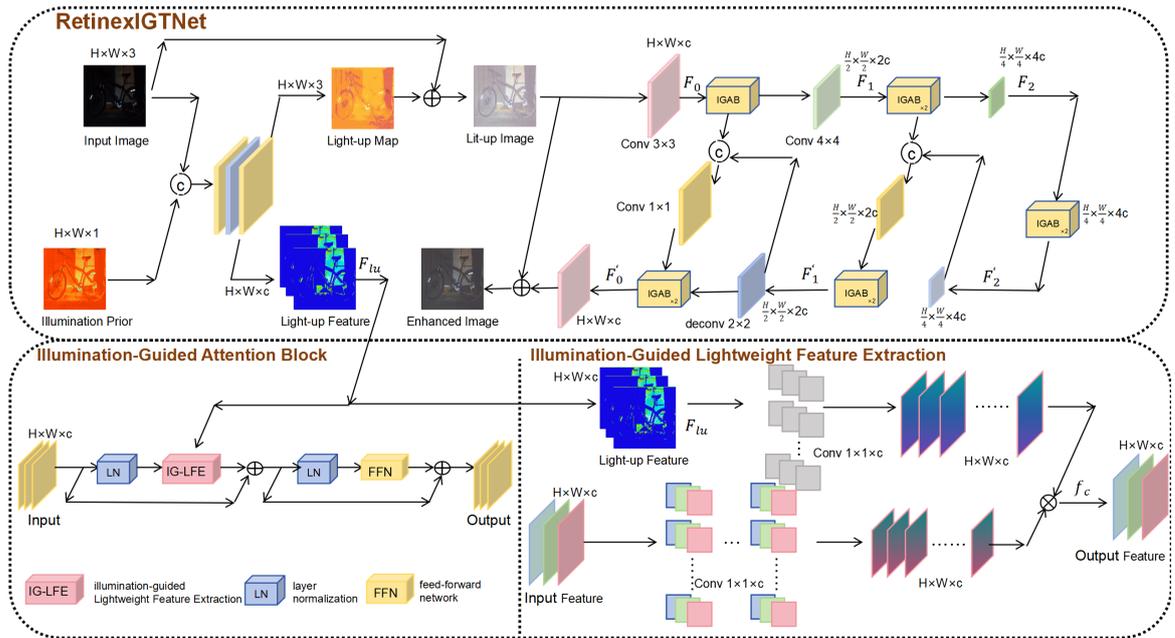


Figure 2. Network architecture of RetinexIGTNet
图 2. RetinexIGTNet 网络结构

3.3. 高效的轻量化卷积 PConv

为了优化计算成本, 我们利用特征图的冗余性, 采用部分卷积(PConv)。如图 3 所示, PConv 通过掩码机制仅在有效区域进行计算, 并动态更新掩码, 增强了处理不完整或遮挡数据的鲁棒性。它仅对部分输入通道进行卷积操作以提取空间特征, 其余通道则不处理。为了实现连续内存访问, 我们选择前几个或后几个连续通道作为特征图的代表进行计算。假设输入和输出特征图通道数相同, PConv 的计算量(FLOPs)可表示为:

$$h \times w \times k^2 \times c_p^2 \quad (4)$$

其中 h 和 w 分别表示特征图在空间维度上的高度和宽度, k 表示卷积核的大小, c_p 表示用于计算的部分通道数。在常见的部分比率 $r = \frac{c_p}{c} = \frac{1}{4}$ 下, PConv 的计算量仅为常规卷积的 $\frac{1}{16}$ 。此外, PConv 的内存访问量更小:

$$h \times w \times 2c_p + k^2 \times c_p \approx h \times w \times 2c_p \quad (5)$$

PConv 仅使用部分通道进行空间特征提取, 但不能直接删除剩余通道, 否则会退化为少通道的常规卷积, 违背减少冗余的目标。因此, 我们保留未处理的通道, 因为它们在后序逐点卷积层中仍然有用。在 Backbone 层中, 卷积和下采样操作使特征图尺寸变小、通道数增加; 在 Neck 层中, 上采样又使特征图放大、通道数减少。我们在代码中将 PConv 贯穿整个网络, 根据特征图和通道数的变化动态调整, 避免初始层中信息丢失, 确保特征信息在所有通道间流动。

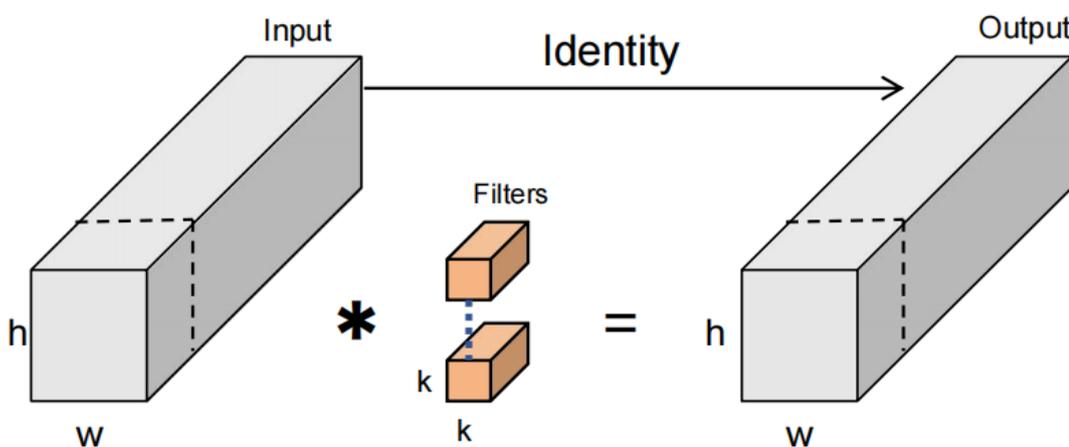


Figure 3. Structure diagram of PConv
图 3. PConv 结构图

3.4. 级联注意力机制 CGA

级联注意力(CGA)是针对视觉 Transformer 中多头自注意力机制(MHSA)的优化方法。它受分组卷积启发, 将特征分片输入不同的注意力头, 显式分解计算到各个头部, 解决了传统 MHSA 中头部冗余导致的计算效率低下问题。具体而言, 每个头只处理输入特征的部分分片 $X_i = [X_{i1}, X_{i2}, \dots, X_{ih}]$, 利用不同的投影矩阵 $W_{ij}^Q, W_{ij}^K, W_{ij}^V$ 计算自注意力。最后, 通过线性层 W_i^P 将所有头部输出的特征拼接, 并映射回原输入的维度。具体结构如图 4。

为了进一步增强模型容量, CGA 在级联结构中计算注意力: 后一层头部的输入会叠加上一层头部的输出, 表示为:

$$X'_{ij} = X_{ij} + \tilde{X}_{i(j-1)}, i < j \leq h \quad (6)$$

其中 X_{ij} 表示第 i 组数据的第 j 个输入分割, $\tilde{X}_{i(j-1)}$ 表示第 i 组数据中第 $(j-1)$ 个头部的输出, X'_{ij} 表示二者相加。这使得后续头部在自注意力计算时能够基于前层的输出逐步细化特征。CGA 在 Q 投影后增加 token 交互层, 联合捕获局部和全局关系, 增强特征表示能力。其优势包括: 特征分片增加注意力头多样性, 减少计算量和参数量; 级联结构加深网络提升容量, 但不增加额外参数且延迟少。总体而言, CGA 通过特征分片和级联设计, 提升了自注意力的效率和表达能力, 减少计算开销的同时提升性能。

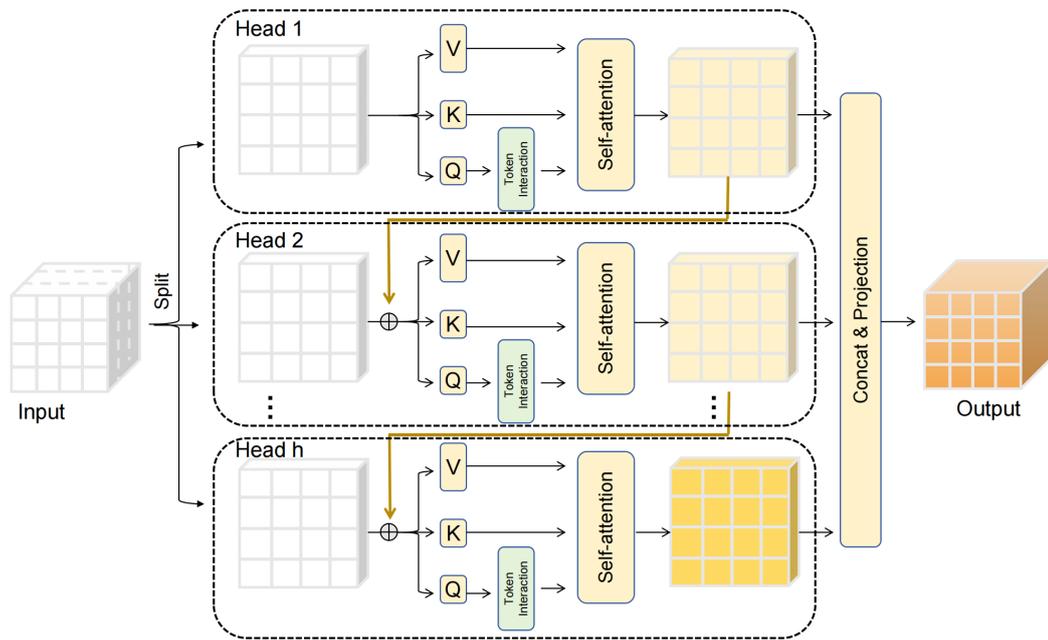


Figure 4. Network architecture of Cascaded Group Attention (CGA)

图 4. Cascaded Group Attention (CGA)网络结构图

4. 实验与结果分析

4.1. 实验条件

实验在配备 NVIDIA GeForce RTX 3050 GPU 的 Windows 11 系统上进行, 支持 CUDA 12.5 和 Python 3.9。测试平台为 NVIDIA Jetson Xavier NX 边缘计算平台, 搭配 AUBOi5 机械臂和 ZED2i 双目相机。为确保公平对比与全面评估, 所有检测模型均进行两轮训练: 第一轮独立训练, 不使用预训练权重; 第二轮迭代训练, 基于第一轮的最佳权重进一步优化。RPC-YOLO 训练中采用随机剪裁和随机翻转等数据增强策略, 输入图像尺寸为 640×640 , batch size 为 5, 初始学习率为 0.01, 训练 300 个 epochs。

4.2. 实验数据集

实验使用了两个真实场景下的弱光图像检测数据集: 公开的 ExDark [16]数据集和私有的“桶”数据集。ExDark 包含 7363 张低光照图像, 涵盖从极弱光到普通弱光的 10 种光照条件, 拍摄场景包括室内、室外、人像、建筑物和道路等。实验中, ExDark 数据集的 80%用于训练, 20%用于测试。私有“桶”数据集包含 1000 张图像, 其中 20%为正常光照, 30%为逆光, 50%为暗光, 同样按照 8:2 的比例划分训练集和测试集。通过这两个数据集, 实验确保了结果的全面性和公平性, 并验证了模型在复杂弱光环境中的鲁棒性和实际应用性能。

4.3. 对比实验

为了验证 RPC-YOLO 在暗光环境下实时目标检测的有效性和优越性, 我们进行了对比实验, 将其与 KinD、SCINet、SNR-Net、RetinexNet 等主流框架进行比较。这些框架均采用先增强再检测的方式处理暗光图像。实验结果如表 1 所示, RPC-YOLO 在 ExDark 数据集的 12 个类别中, 有 6 个类别的检测性能领先, 平均 mAP 也高于其他模型, 证明了其优越性。

表 2 和图 5 展示了我们模型在 Params (参数量)、Flops (计算量)和 mAP (检测精度)等指标上的综合性

能表现。实验结果表明, 我们的模型在保证精准度的同时, 显著降低了模型大小和对设备算力的依赖。在公开数据集(A)和私有数据集(B)的对比实验中, 各项指标最高的结果以红色标注, 第二高的结果以蓝色标注。我们的模型在综合性能上表现出色。

Table 1. Performance of different network models on the ExDark dataset

表 1. 不同网络模型再 ExDark 数据集上各类的性能表现

Methods	Bicycle	Boat	Bottle	Bus	Car	Cat	Chair	Cup	Dog	Motor	People	Table	Mean
KinD [5]	72.2	66.5	58.9	83.7	74.5	55.4	61.7	61.3	63.8	63.0	70.5	47.8	65.0
SCINet [8]	74.6	65.3	65.8	85.4	76.3	59.4	57.1	60.5	65.6	63.9	69.1	45.9	65.6
SNR-Net [17]	75.3	64.4	63.6	85.3	77.5	59.1	54.1	59.6	66.3	65.2	69.1	44.6	65.3
RetinexNet [18]	73.8	62.8	64.8	84.9	80.8	53.4	57.2	68.3	61.5	51.3	65.9	43.1	64.0
Retinexformer	67.0	66.7	70.8	84.7	77.6	61.2	53.5	60.7	67.5	63.4	69.5	46.0	67.5
RPC-YOLO	79.0	66.5	73.8	85.0	81.2	60.5	61.1	68.5	67.4	66.0	70.9	44.9	68.7

Table 2. Comparison of different models in params, flops, and average mAP

表 2. 不同模型在参数量, 浮点运算量, 平均 mAP 的对比

Model	Params (M)	FLOPs (G)	mAP@0.5 (%)	
			A	B
IAT + YOLOV3 [15]	3.03	22.6	0.672	0.969
SCINet + YOLOV5 [8]	4.76	5.3	0.65	0.971
Retinexformer + YOLOV5	4.82	28.4	0.68	0.972
RPC-YOLO (ours)	2.64	23	0.69	0.988

针对于暗光环境下的实时目标检测任务, 满足实时性是必要条件, 更高的 FPS 表示模型能更快地检测和标注目标, 本文提出的模型 FPS 达到 35.79, 完全满足实时性任务。

4.4. 可视化分析

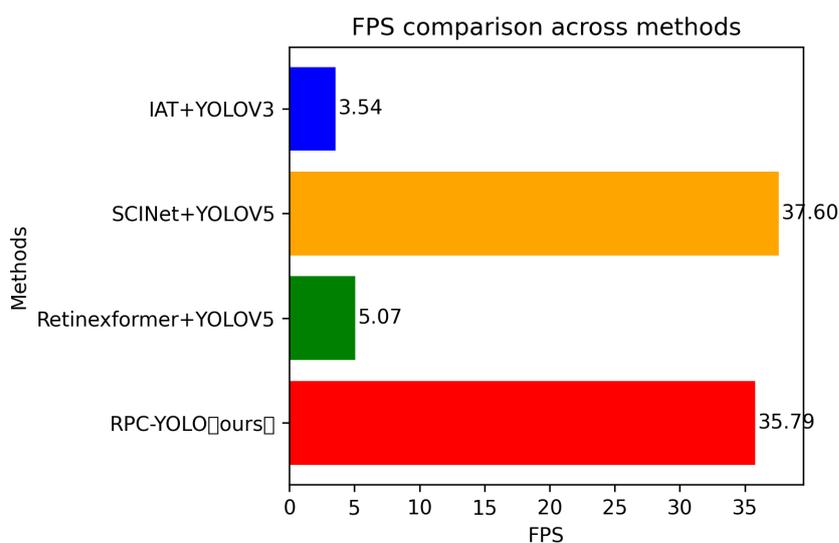


Figure 5. Comparison of FPS values for different models

图 5. 不同模型的 FPS 值对比

为了更好地表现我们模型的进步和优势, 我们从暗图增强后的效果图、置信度、热力图三方面进行可视化分析。

图 6 展示了在极端黑暗条件下本文模型的调光效果。第一行图像呈现的是数据集中极暗的原始图像, 而第二行则展示了经过我们算法处理后的图像结果。可以清晰地观察到, 无论是图像的清晰度, 还是被检测目标的类别和轮廓特征, 都得到了显著改善。



Figure 6. Demonstration of model performance on public datasets
图 6. 模型在公开数据集上的效果展示

在机器视觉领域, 人眼对图像的关注点受主观情感和 Experience 影响, 而计算机则基于算法和数学模型, 客观分析图像的数值特征。为了展示计算机对改进图像的关注度, 我们引入热力图(如图 7), 通过颜色明亮度直观呈现其对特定目标的关注程度, 帮助优化算法并提升性能。

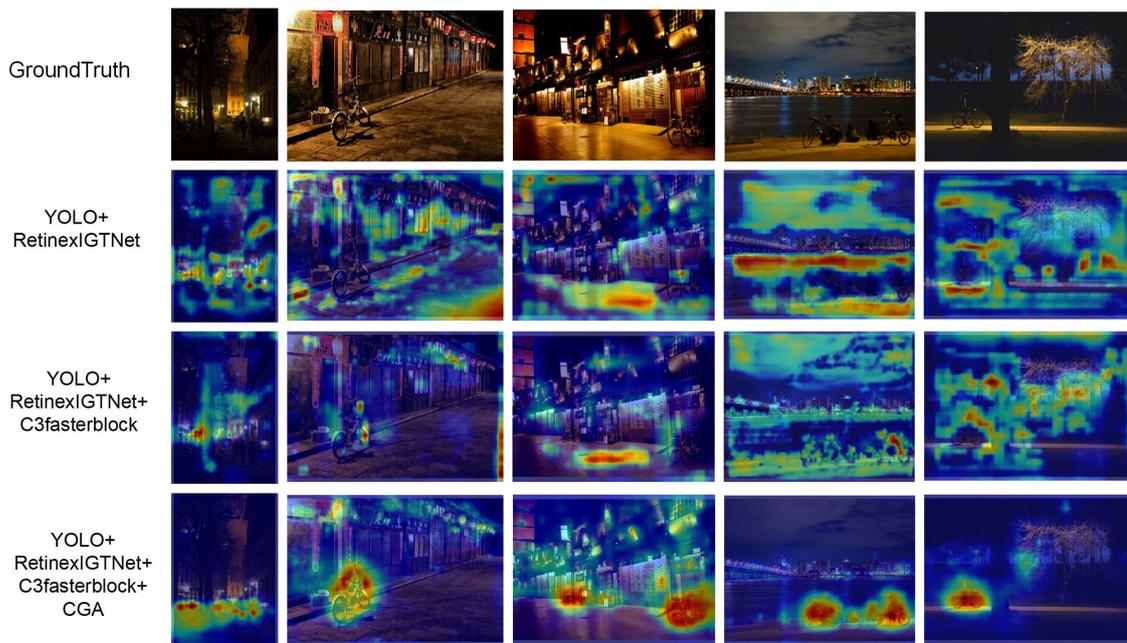


Figure 7. Heatmap visualization of different stages in the network
图 7. 网络各阶段的热力图展示

改进后的 RetinexIGTNet 与 YOLO 结合虽能满足人眼视觉需求, 但热力图显示计算机关注点仍较分散。引入 C3FasterBlock 和 CGA 注意力机制后, 热力图高亮部分逐渐聚焦于目标, 表明模型在提升图像可视性的同时, 实现了计算机视角下的精准目标识别和定位, 验证了其在不同层面上的优良性能。

如图 8 所示, RPC-YOLO 模型在置信度方面表现优异, 减少了误报, 并能在复杂场景中全面检测多个目标, 无论大尺度还是小尺度目标均能精准识别, 确保检测结果可靠且全面。

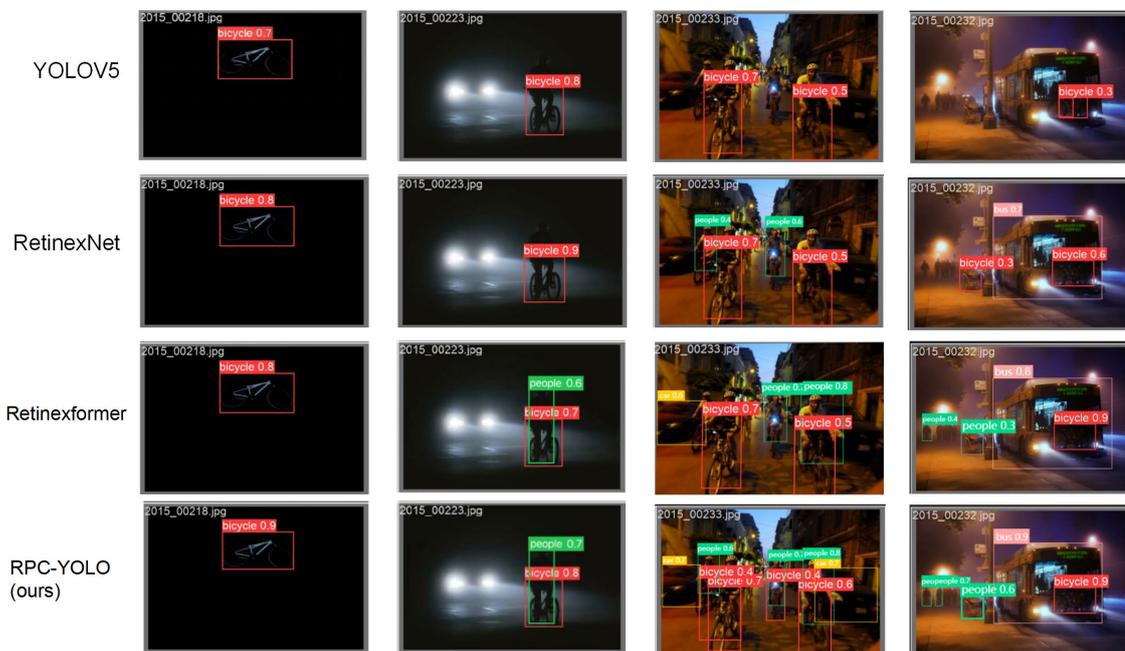


Figure 8. Detection results of different models on public datasets

图 8. 不同模型在公开数据集上的检测结果

在实际应用测试中, 图 9 展示了将我们的网络模型部署在机械臂上后对目标(如“桶”)的检测和定位结果。原 YOLO 模型在暗光环境下存在误检测和漏检测问题, 导致无法将目标坐标信息准确传递给下位机, 进而影响机械臂的抓取动作。而经过我们设计的模型检测后, 物体框的位置和置信度信息准确, 未出现漏检和误检, 符合实际需求, 证明了模型在暗光环境下的有效性和可靠性。



Figure 9. Detection results of RPC-YOLO on the private dataset

图 9. RPC-YOLO 在私有数据集上的检测效果

5. 总结

本文提出了新型的暗光环境下用于边缘计算平台的目标检测网络 RPC-YOLO, 该模型结合了表现优异的暗光调节模块 RetinexIGTNet 与主流 YOLO 网络, 并引入轻量化部分卷积和级联注意力机制。实验

结果表明, 该方法在参数量、FLOPS、mAP、FPS 上均取得了显著提升, 完全适用于边缘计算平台, 此外, 本方法在极暗、复杂背景及各类大小目标的情况下均表现出色, 证明了其良好的适用性和鲁棒性。

参考文献

- [1] 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>
- [2] 冯欣, 王思平, 张智先, 焦晓宁, 薛明龙. 一种面向机器视觉感知的暗光图像增强网络[J]. *计算机应用研究*, 2024, 41(6): 1910-1915.
- [3] Wei, C., Wang, W.J., Yang, W.H. and Liu, J.Y. (2018) Deep Retinex Decomposition for Low-Light Enhancement. *British Machine Vision Conference 2018, BMVC 2018*, Newcastle, 3-6 September 2018, 1-12.
- [4] Zhang, Y., Guo, X., Ma, J., Liu, W. and Zhang, J. (2021) Beyond Brightening Low-Light Images. *International Journal of Computer Vision*, **129**, 1013-1037. <https://doi.org/10.1007/s11263-020-01407-x>
- [5] Zhang, Y.H., Zhang, J.W. and Guo, X.J. (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>
- [6] Cai, Y., Bian, H., Lin, J., Wang, H., Timofte, R. and Zhang, Y. (2023) Retinexformer: One-Stage Retinex-Based Transformer for Low-Light Image Enhancement. 2023 *IEEE/CVF International Conference on Computer Vision (ICCV)*, Paris, 2-6 October 2023, 12504-12513. <https://doi.org/10.1109/iccv51070.2023.01149>
- [7] Yin, X., Yu, Z., Fei, Z., Lv, W. and Gao, X. (2023) PE-YOLO: Pyramid Enhancement Network for Dark Object Detection. In: Iliadis, L., et al., Eds., *International Conference on Artificial Neural Networks*, Springer, 163-174. https://doi.org/10.1007/978-3-031-44195-0_14
- [8] Ma, L., Ma, T., Liu, R., Fan, X. and Luo, Z. (2022) Toward Fast, Flexible, and Robust Low-Light Image Enhancement. 2022 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, New Orleans, 18-24 June 2022, 5637-5646. <https://doi.org/10.1109/cvpr52688.2022.00555>
- [9] 李子姝, 谢人超, 孙礼, 等. 移动边缘计算综述[J]. *电信科学*, 2018, 34(1): 87-101.
- [10] Girshick, R., Donahue, J., Darrell, T. and Malik, J. (2014) Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation. 2014 *IEEE Conference on Computer Vision and Pattern Recognition*, Columbus, 23-28 June 2014, 580-587. <https://doi.org/10.1109/cvpr.2014.81>
- [11] Girshick, R. (2015) Fast R-CNN. *Proceedings of the IEEE International Conference on Computer Vision*, Santiago, 7-13 December 2015, 1440-1448. <https://doi.org/10.1109/ICCV.2015.169>
- [12] Ren, S., He, K., Girshick, R. and Sun, J. (2017) Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **39**, 1137-1149. <https://doi.org/10.1109/tpami.2016.2577031>
- [13] Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C., et al. (2016) SSD: Single Shot Multibox Detector. *Computer Vision-ECCV 2016: 14th European Conference*, Amsterdam, 11-14 October 2016, 21-37. https://doi.org/10.1007/978-3-319-46448-0_2
- [14] Jocher, G., Chaurasia, A., Stoken, A., et al. (2022) Ultralytics/yolov5: v6.1—TensorRT, TensorFlow Edge TPU and OpenVINO Export and Inference. Zenodo.
- [15] Cui, Z., Li, K., Gu, L., et al. (2022) You Only Need 90k Parameters to Adapt Light: A Light Weight Transformer for Image Enhancement and Exposure Correction.
- [16] Loh, Y.P. and Chan, C.S. (2019) Getting to Know Low-Light Images with the Exclusively Dark Dataset. *Computer Vision and Image Understanding*, **178**, 30-42. <https://doi.org/10.1016/j.cviu.2018.10.010>
- [17] Xu, X., Wang, R., Fu, C. and Jia, J. (2022) SNR-Aware Low-Light Image Enhancement. 2022 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, New Orleans, 18-24 June 2022, 17714-17724. <https://doi.org/10.1109/cvpr52688.2022.01719>
- [18] Wei, C., Wang, W., Yang, W. and Liu, J. (2018) Deep Retinex Decomposition for Low-Light Enhancement.