

## 基于照度图引导的低照度图像增强网络

黄淑英<sup>1)</sup>, 黎为<sup>2)</sup>, 杨勇<sup>3)\*</sup>, 万伟国<sup>2)</sup>, 赖厚增<sup>2)</sup>

<sup>1)</sup>(天津工业大学软件学院 天津 300387)

<sup>2)</sup>(江西财经大学软件与物联网工程学院 南昌 330032)

<sup>3)</sup>(天津工业大学计算机科学与技术学院 天津 300387)

(yangyong@tiangong.edu.cn)

**摘要:** 在低照度环境下采集的图像, 由于光照的不均匀性, 存在能见度差、对比度低和颜色失真等问题. 现有的大多数低照度图像增强方法存在过增强或欠增强的现象, 影响视觉感知和后续目标检测任务. 针对上述问题, 提出一种基于照度图引导的低照度图像增强网络. 首先根据低照度图像的灰度分布特点构造对应的照度图, 度量低照度图像不同区域块的明暗程度; 然后利用照度图作为网络增强的引导图, 与低照度图像一起送入图像增强网络来获得增强后的图像. 为了解决训练数据不足的问题, 提出一种基于内循环和概率旋转的数据增强方法来扩充训练数据样本的数量和多样性; 同时, 针对目前图像增强方法中普遍存在照度不均匀的问题, 基于直方图匹配的思想构建一种直方图损失函数, 约束并指导网络的训练. 在合成数据集 LOL 和真实图像上的实验结果表明, 所提网络在低照度图像增强方面获得了更好的主观视觉效果; 与经典的 RetinexNet 方法相比, 所提方法在 PSNR 和 SSIM 客观定量指标上分别提高了 7.905 dB 和 0.328; 该网络对后续目标检测任务的检测率可提高 10.17%~17.19%.

**关键词:** 低照度图像增强; 照度图引导; 直方图损失函数; 概率旋转增强; 目标检测

中图法分类号: TP391.4

DOI: 10.3724/SP.J.1089.2024.19779

## Low-Light Image Enhancement Network Guided by Illuminance Map

Huang Shuying<sup>1)</sup>, Li Wei<sup>2)</sup>, Yang Yong<sup>3)\*</sup>, Wan Weigu<sup>2)</sup>, and Lai Houzeng<sup>2)</sup>

<sup>1)</sup>(School of Software, Tiangong University, Tianjin 300387)

<sup>2)</sup>(School of Software and Internet of Things Engineering, Jiangxi University of Finance and Economics, Nanchang 330032)

<sup>3)</sup>(School of Computer Science and Technology, Tiangong University, Tianjin 300387)

**Abstract:** Images captured in low-light environment suffer from poor visibility, low contrast and color distortion due to the uneven illumination. Most of the existing low-light image enhancement methods have problems of over- or under-enhancement, which affects visual perception and subsequent object detection tasks. To address these problems, this paper proposed a low-light image enhancement network based on illumination map guidance. First, according to the grayscale distribution characteristics of the low-light images, the corresponding illumination map is constructed to measure the brightness and darkness of different areas of the low-light image; then, the illumination map is regarded as a guidance map and fed into the image enhancement network together with the low-light image to obtain the enhanced image. In addition, in order to solve the problem of insufficient training data, a data enhancement method based on inner loop and probability rotation is proposed to expand the number and diversity of training data samples; simultaneously, a

收稿日期: 2022-06-14; 修回日期: 2022-12-07. 基金项目: 国家自然科学基金(61862030, 62072218); 江西省自然科学基金(20192ACB20002, 20192ACBL21008). 黄淑英(1977—), 女, 博士, 教授, 硕士生导师, CCF 会员, 主要研究方向为图像处理、机器学习; 黎为(1998—), 男, 硕士研究生, 主要研究方向为图像处理; 杨勇(1976—), 男, 博士, 教授, 博士生导师, CCF 杰出会员, 论文通信作者, 主要研究方向为图像处理、模式识别; 万伟国(1991—), 男, 博士, 讲师, 硕士生导师, CCF 会员, 主要研究方向为图像处理; 赖厚增(1995—), 男, 硕士研究生, 主要研究方向为图像处理.

histogram loss function is designed based on the idea of histogram matching to constrain and guide the training of the network to overcome the problem of uneven illumination in current image enhancement methods. Experimental results on synthetic dataset LOL and real images demonstrate that the proposed network achieves better subjective visual effects in low-light image enhancement. Compared with the classical RetinexNet method, the proposed method improves the objective quantitative indexes of PSNR and SSIM by 7.905 dB and 0.328, respectively; moreover, the detection rate of the proposed network for subsequent object detection tasks can be improved by 10.17% to 17.19%.

**Key words:** low-light image enhancement; guidance of illuminance map; histogram loss function; probability rotation enhancement; object detection

在光照不足的环境中, 拍摄的图像通常存在能见度差、对比度低、颜色丢失和噪声等现象. 在实际应用中, 需要利用图像增强技术<sup>[1]</sup>来提高图像的质量. 图像增强技术具有广泛的应用, 如可用于日常摄影, 帮助用户在低光环境下捕捉高质量的图像; 也可用于各种智能系统, 如自动驾驶、视频监控、目标检测. 近年来, 图像增强技术发展迅速, 很多有效的方法被用于低照度图像增强中<sup>[2]</sup>. 目前, 图像增强的方法大致分为基于直方图均衡化的增强方法<sup>[3-5]</sup>、基于 Retinex 理论的增强方法<sup>[6-11]</sup>和基于深度学习技术的增强方法<sup>[12-16]</sup>3 类.

基于直方图均衡化的图像增强方法侧重于对输入图像的直方图分布进行调整, 以显示更多的视觉信息. 直方图表征了图像中像素强度的分布情况, 在图像整体偏暗的情况下, 对其直方图分布进行均衡化可以调整图像的对比度. Lee 等<sup>[3]</sup>提出一种基于二维直方图分层差分的对比度增强算法, 通过放大相邻像素之间的灰度差异增强图像的对比度; Lin 等<sup>[4]</sup>提出一种依次进行颜色通道拉伸、直方图平均和重映射的对比度增强算法, 通过对颜色通道进行拉伸更好地恢复场景中的颜色信息, 采用对直方图平均再均衡化的方式增强图像的内容, 并通过对直方图进行重映射减少均衡化经常出现的伪影现象. 为了更好地恢复图像的内容, Sujee 等<sup>[5]</sup>将多分辨率的思想与直方图均衡化结合, 利用金字塔技术对低照度图像分解, 对不同分辨率的图像进行直方图匹配增强, 最大限度地提取图像中的信息. 基于直方图均衡化的低照度图像增强算法虽然能通过简单地拉伸图像灰度的动态范围增强对比度, 但是没有考虑环境中光照的影响, 因此该类算法会出现增强过度或者增强不足的问题.

Retinex 理论是由著名学者 Land<sup>[6]</sup>提出的一种颜色恒常理论, 主要思想是人眼所感知的颜色是

由目标物体表面反射的光线和环境照度的共同作用决定的. 由 Retinex 理论可知, 低照度图像是正常照度的图像和环境照度的组合, 通过去除图像中环境照度的影响可以得到正常照度的图像. 如何从低照度图像中分离出环境照度是一个病态问题, 学者通常会加以一定的先验和约束条件进行优化求解. Jobson 等<sup>[7]</sup>提出一种带颜色恢复的多尺度 Retinex 增强算法, 该算法结合动态范围压缩、颜色一致性和人类视觉的稳定性对图像的亮度和对比度进行复原; Dong 等<sup>[8]</sup>提出一种有效的低照度图像增强算法, 先对低照度图像进行取反, 使其在视觉上接近去雾图像, 然后利用去雾算法处理, 再次取反得到增强后的图像; Fu 等<sup>[9]</sup>采用基于形态学近似的照度估计算法将图像分解为反射分量和照度分量, 然后对照度分量分别进行全局亮度提升和局部对比度增强操作, 最后采用多尺度的融合方式获得照度图像并求出正常照度的图像; Guo 等<sup>[10]</sup>通过寻找图像像素在红、绿和蓝 3 个颜色通道的最大值构建初始照度图, 然后利用一个预定的结构对初始照度图进行细化得到最终的照度图, 进一步实现图像的照度增强. 受到人眼视觉的启发, Ying 等<sup>[11]</sup>提出一个多阶段的多曝光图像融合框架, 第 1 个阶段通过模拟人眼来调整曝光, 生成多曝光图像集; 第 2 个阶段模拟人脑机制来融合多曝光图像, 得到最终的增强图像. 基于 Retinex 模型的低照度图像增强方法的关键是对照度图像估计的准确性, 其依赖于先验约束条件的精确定义, 然而, 一种先验条件很难适用于各种真实场景的图像增强.

卷积神经网络具有强大的特征学习能力, 已经成为解决计算机视觉任务问题的主要工具, 在低照度图像增强任务中也被广泛应用. Lore 等<sup>[12]</sup>最早提出一种基于深度学习的图像增强框架, 通

过设计一个深度自编码器来识别低照度图像的特征,能自适应地增强图像的亮度,可同时实现图像的增强和去噪;Wei 等<sup>[13]</sup>提出一种基于 Retinex 模型的分解网络,首先把输入图像分解为照度图和反射图,然后对照度图和反射图分别进行去噪和亮度增强,最后重建 2 个分量得到正常照度图像;Wang 等<sup>[14]</sup>将低照度图像增强看成是一个残差学习问题,即通过估计低照度图像和正常照度图像之间的残差获得亮度增强后的图像;Xu 等<sup>[15]</sup>提出一种基于频率分解的亮度增强网络,首先在抑制噪声的情况下恢复低频层的内容信息,然后对图像高频层的细节进行增强;Zhang 等<sup>[16]</sup>提出一种基于 Retinex 模型分解的亮度增强网络,其设计的映射功能可以根据用户的不同需求灵活地调整亮度,并能有效地去除因增强较暗区域的亮度而放大的视觉缺陷。

基于深度学习的低照度图像增强方法虽然取得了较好的效果,但依然存在一些问题和挑战。首先,现有的低照度图像增强方法忽略了真实环境照度不均匀这一事实,在对较亮和较暗的区域进行相同程度的增强时,导致增强后的图像存在增强不足或增强过度的问题;其次,由于缺乏丰富和高质量的数据集,网络不能很好地从图像中学习低照度特征,导致网络的泛化性能较差,对真实场景的处理效果不佳;除此之外,大多数现有的低照度图像增强方法都是从噪声不足的数据集中学习的,但是真实场景的低照度图像中往往会包含大量的噪声,因此增强后的图像会存在噪声被放大的问题。

基于上述分析,本文针对现有低照度图像增强存在的问题,提出一种基于照度图引导的低照

度图像增强深度学习网络。首先通过对低照度图像计算得到反映图像不同区域亮度情况的引导图;然后构建一个多尺度注意力 U-Net 残差网络;最后将低照度图像和引导图拼接后送入网络进行特征学习,获得亮度增强后的图像。

本文首先提出一种基于照度图引导的低照度图像增强网络。通过构建与低照度图像对应的照度图,来引导增强网络特征的学习,以避免图像增强过度或增强不足现象,使图像更加符合人的视觉观察。然后提出一种内循环和概率旋转的数据增强方法,通过增加训练数据样本的规模和多样性,提高网络的泛化性。最后为了更好地指导网络进行训练,使增强后的图像更接近真实的自然场景图像,基于直方图匹配的思想提出一种直方图损失函数,利用多损失函数联合训练策略,使网络学习到的特征和信息更全面。

## 1 本文网络

### 1.1 网络框架

受到不均匀光照的影响,低照度图像不同区域的亮度会有所不同。现有的一些方法在进行亮度增强时对所有区域进行一致性增强,导致图像出现过增强或增强不足等问题。针对这一问题,本文提出一种基于照度图引导的低照度图像增强网络,如图 1 所示。首先对输入的低照度图像计算一幅照度引导图,反映图像不同区域的亮度情况;然后将低照度图像和引导图做拼接操作后,将多尺度的图像输入到 U-Net 中进行特征学习;为了对图像不同明暗度的区域执行不同程度的亮度增强操




图 1 本文网络框架

作, 将引导图作为一种注意力映射, 并将其与网络输出特征图相乘来调整图像的局部亮度; 最后利用一个过渡卷积层将输入图像的浅层细节特征传递到深层, 实现浅层特征的复用来增强图像的特征, 获得亮度增强后的图像。

### 1.1.1 照度引导图的构建

为了使增强后的图像整体亮度均匀, 针对亮度不同的区域采用不同的增强力度思想构建增强网络。一幅图像中较亮区域对应的灰度值较大, 较暗区域对应的灰度值较小, 因此在图像增强过程中, 对于灰度值较大的区域采用相对较小的增强力度, 对于灰度值较小的区域则采用较大的增强力度。通过观察图像可以发现, 图像的反色图像正好与图像灰度值的强度相反, 即与选择的增强力度趋势一致。因此, 本文网络中利用引导图可以指导网络学习针对不同区域的增强力度, 对于比较暗的区域赋予较大的增强力度, 解决增强不足的问题; 对于比较亮的区域减弱增强力度, 避免过度增强, 使整体图像亮度均衡, 更符合人眼的视觉观察。基于此, 本文利用低照度图像的反色变换构建照度引导图, 指导网络的特征学习。

首先将低照度图像的  $R, G, B$  这 3 个通道归一化为  $[0,1]$ , 然后对 3 个通道像素的最大值取反, 得到低照度图对应的引导图。给定一幅低照度图像  $L$ , 其对应的照度引导图定义为

$$G = 1 - \max_{c \in \{R, G, B\}} (L^c) \quad (1)$$

其中,  $L^c$  表示低照度图像  $L$  的颜色通道图,  $G$  表示照度引导图。分析式(1)可以得出, 图像中亮度较低的区域对应的引导图越亮, 即灰度值越大。亮度较高的区域对应的引导图则越暗, 即灰度值越小。图 2 所示为低照度图像和照度引导图的关系示意图。可以看出, 图 2a 所示的低照度图像虽然整体偏暗, 但是仍然能观察到不同区域间存在亮度的差别; 图 2b 所示为通过直方图均衡化增强后的图像, 有很好的视觉感知; 图 2c 中, 低照度图像所对应的照度引导图反映图像增强力度的趋势, 因此可以用于指导网络在训练时对不同区域投放不同的注意力。

### 1.1.2 多尺度注意力 U-Net

U-Net 已经在图像复原和增强任务中获得了成功的应用<sup>[17]</sup>。为了更好地复用网络提取的浅层特征和提高网络的特征提取能力, 本文构建了一种多尺度注意力 U-Net。该网络以引导图和低照度图像作为输入, 其编码部分包含一个卷积层和 4 个



图 2 低照度图像和照度引导图的关系示意图

多尺度的特征提取层; 同样地, 解码部分采用了一个与编码部分相反的结构, 同时每个尺度上增加一个跳转链接来实现浅层特征的复用。为了更好地利用不同尺度的特征信息, 输入的低照度图像被降采样 3 次并分别采用一个卷积层进行特征提取, 将提取的浅层特征拼接到编码部分对应的尺度特征提取层中, 以增加每个尺度提取特征的丰富性。为了使网络在提取特征过程中对不同区域投放不同的注意力, 将解码部分的输出结果与引导图进行加权相乘, 实现对学习到的特征有侧重的调整。最后, 利用一个过渡卷积层将浅层特征传递到深层, 进一步实现特征的复用来进行特征增强, 该过渡卷积层的作用已在文献[18]中被证实是有效的。

多尺度注意力 U-Net 利用低照度图像和引导图作为输入提取特征, 可以更好地进行信息交互和融合, 使得网络在提取特征的过程中保持较好的结构信息。该结构中, 所有卷积层的卷积核大小都是  $3 \times 3$ , 每次进行卷积操作时卷积核的个数即为输出特征图的通道数; 根据 U-Net 的各个尺度大小进行对应的匹配; 激活函数使用 PReLU。每个多尺度的特征提取层则包含一个卷积层和一个通道注意力残差模块, 该模块的引入可以有选择性地增强图像不同区域的特征。

通道注意力残差模块的结构如图 3 所示。(1) 将接收到的输入送入一个卷积块(包含 2 个卷积层和一个 PReLU 层)进行特征提取, 获得  $C$  个通道、大小为  $[H, W]$  的特征图。(2) 对这些特征图进行通道注意力操作<sup>[19]</sup>: 首先经过一个自适应的全局平均池化操作, 保证输出通道维度与输入通道维度一

致为  $[1, 1, C]$ ；然后通过一个  $1 \times 1$  卷积进行降维操作，输出维度为  $[1, 1, C/R]$  的特征矢量；再经过一个激活函数增加卷积层之间的非线性关系，并通过一个  $1 \times 1$  卷积使通道数恢复原来的  $[1, 1, C]$ ；最后使用 Sigmoid 函数计算对应通道的概率值，作为对应通道的注意力权重系数，与前面最初卷积块提取的特征图做乘法，即完成根据通道注意力权重对特征图的调整。(3) 做一个全局的残差跳转，使得输入  $X$  与经过通道注意力调整的特征图进行逐像素的相加操作，输出该模块的特征图  $Y$ 。

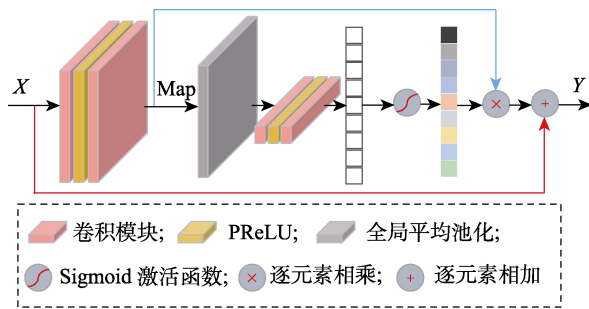


图 3 通道注意力残差模块

## 1.2 数据增强策略

训练数据集对网络模型的训练十分重要，样本数量不足会导致训练出来的模型泛化能力不够。针对样本不足的任务，可以通过数据增强从已有的训练样本中生成一些新的数据，从而扩大训练数据。为此，本文提出一种概率旋转和内循环数据增强方法来扩充训练数据样本的数量和多样性。

概率旋转增强指在网络训练之前对已有的训练图像进行随机的旋转增强，再送入网络进行训练。本文定义的旋转方式有 8 种：对原始图像样本顺时针旋转  $90^\circ$ 、逆时针旋转  $90^\circ$ 、上下翻转、左右翻转、先上下翻转一次再顺时针旋转  $90^\circ$ 、先上下翻转一次再逆时针旋转  $90^\circ$ 。通过这种随机的样本旋转可以增加训练样本的多样性，降低模型对一些属性的依赖，进一步提升网络模型的泛化能力。

内循环数据增强指在训练过程中，利用网络初始的输出结果增加网络的训练样本。在前几个训练周期网络学习到的特征还比较少，此时网络的输出结果仍然与输入的低照度图像比较近似，但已经发生了改变，因此可以将网络的输出结果加入到训练集中增加训练数据的多样性，与原始训练数据一起送入网络中继续进行网络训练。本文实验中，根据经验选择第 3 个迭代周期和第 6 个迭代周期的网络模型产生的结果作为进一步进行

网络训练的样本，将生成样本和原始样本一起作为输入，送入网络中重新开始网络训练。利用这种内循环的数据增强方式，可以产生一些不同程度不同细节的低照度图像，通过增加训练样本的数量和种类提升模型的鲁棒性。

## 1.3 构建损失函数

为了使增强后的图像更逼近正常亮度下的参考图像，本文根据图像灰度的空间及统计分布特性，如边缘纹理信息、像素和直方图分布差异等，定义一种多元联合损失函数

$$L = \alpha L_{\text{MSE}} + \beta L_{\text{edge}} + \lambda L_{\text{hist}} \quad (2)$$

其中， $L_{\text{MSE}}$ 、 $L_{\text{edge}}$  和  $L_{\text{hist}}$  分别是均方误差 (mean square error, MSE) 损失、边缘损失和直方图损失函数； $\alpha$ 、 $\beta$  和  $\lambda$  分别对应的 3 个损失的权重贡献系数，根据经验设置为 5, 3 和  $2.5 \times 10^{-6}$ 。

(1) MSE 损失函数。衡量低照度图像和参考图像之间的像素值差异，定义为

$$L_{\text{MSE}} = \frac{1}{N} \sum_{i=1}^N (H_i - E_i)^2 \quad (3)$$

其中， $H_i$  和  $E_i$  分别表示参考图像和亮度增强后的图像， $N$  为图像数量。

(2) 边缘损失函数。由于低照度图像存在边缘和纹理细节不清晰的问题，因此本文利用边缘损失函数对亮度增强后图像和参考图像之间的高频分量进行约束，使得增强后的图像尽可能恢复出更多的纹理信息。边缘损失函数定义为

$$L_{\text{edge}} = \frac{1}{N} \sqrt{\|\Delta(H_i) - \Delta(E_i)\|^2 + \varepsilon^2} \quad (4)$$

其中， $\Delta$  表示拉普拉斯算子； $\varepsilon$  表示一个常数，实验中根据经验设置为  $10^{-3}$ 。

(3) 直方图损失函数。低照度图像的直方图中，图像的像素点主要分布在像素级比较低的范围；而正常亮度图像的直方图分布则比较均匀。因此本文提出一种直方图损失函数来计算亮度增强后的图像和参考图像在直方图分布上的差异，该直方图损失函数定义为

$$L_{\text{hist}} = \frac{1}{N} \sum_{i=1}^N |H_i^{\text{hist}} - E_i^{\text{hist}}| \quad (5)$$

其中， $H_i^{\text{hist}}$  和  $E_i^{\text{hist}}$  分别表示参考图像和亮度增强后的图像的直方图，表征图像的灰度值的统计分布情况。由于直方图体现了不同像素强度的分布情况，因此利用直方图损失函数来约束网络训练可以对图像的全局亮度进行调整。

## 2 实验结果与分析

为了验证本文方法的有效性, 将该方法与最新流行的 7 种低照度图像增强方法进行主观和客观质量评价, 包括 BIMEF<sup>[11]</sup>, RetinexNet<sup>[13]</sup>, EnlightenGAN<sup>[20]</sup>, SSIEN<sup>[21]</sup>, PDN<sup>[22]</sup>, KIND++<sup>[23]</sup> 和 UNIE<sup>[24]</sup>. 其中, BIMEF 是传统的亮度增强方法; 其他方法都是基于深度学习的亮度增强方法. 客观评价指标采用峰值信噪比(peak signal-to-noise ratio, PSNR), 结构相似性(structural similarity index, SSIM), 平均亮度(average brightness, AB)<sup>[25]</sup>和亮度循环误差(lightness order error, LOE)<sup>[26]</sup>, 它们被广泛用于图像复原和图像增强中, 可以有效地度量算法的性能.

### 2.1 实验设置和数据集

本文网络是在一台含 4 张 Tesla V100 GPU 的计算机, Linux+PyTorch 环境下训练实现的. 网络训练的批处理大小为 16, 迭代次数为 200 次, 采用 Adam 优化器; 设置初始学习率为  $2 \times 10^{-4}$ , 并使用余弦退火策略将学习率稳定降至  $2 \times 10^{-6}$ .

网络训练使用 2 种数据集: (1) LOL 数据集<sup>[13]</sup>. 包含 485 对低光/正常光图像和 15 幅测试图像. 该数据集的低照度图像通过调节相机的曝光程度获得, 即通过改变相机的曝光时间和 ISO, 同时固定相机的其他参数获取低照度图像<sup>[13]</sup>. (2) 为了增加网络的泛化性, 对 RAISE 数据集<sup>[27]</sup>中的图像进行曝光度调整, 得到低光/正常光图像数据集. 从 RAISE 数据集中选择 1 315 幅原始的正常光照图像; 然后利用 Adobe Lightroom 提供的接口对正常光照图像进行曝光度调整, 合成低光照的图像, 即可获得 1 315 对低光/正常光图像; 通过这种方式,

使得训练集的总数据量为 1 800 对低光/正常光图像, 对数据集进行增强, 最终获得 5 400 对低光/正常光图像用于网络训练, 训练图像的尺寸为  $384 \times 384$  像素.

### 2.2 合成数据实验

图 4 和图 5 所示为所有方法在 2 组低照度图像上的亮度增强结果. 可以看出, BIMEF 方法获得的增强结果存在颜色失真、纹理细节丢失和亮度较暗的问题; RetinexNet 方法虽然增强图像的亮度并恢复了一些纹理细节信息, 但是存在较严重的偏色问题; EnlightenGAN 方法增强后的图像仍然比较暗, 在亮度和视觉方面都没有产生令人满意的结果, 而且也存在偏色问题; SSIEN 和 PDN 方法增强的结果同样也存在颜色失真和亮度较暗的问题; KIND++和 UNIE 方法的增强结果总体上比较接近参考图像, 但是在一些区域, 如图 4g, 图 4h 红色线框的区域中, 这 2 种方法没有恢复出图像的真实颜色; 由于低照度图像增强往往存在噪声被放大的问题, 大多数方法的增强结果都不可避免地出现了不同程度的噪声; 本文方法在进行亮度增强的同时考虑了图像局部照度的差异, 对整体亮度的调整更加自然, 在抑制图像噪声的同时也避免了边缘和纹理的丢失, 因此无论在颜色、纹理信息以及亮度方面, 都更加接近于参考图像.

为了客观地评估本文方法的有效性, 表 1 所示为 8 种方法在 LOL 数据集上的客观评价指标比较. 可以看出, 本文方法的 PSNR, SSIM 和 LOE 指标值优于所有对比的方法, 其中, PSNR 比第 2 名高出 2.201 dB; 在 AB 指标上, 本文方法获得了排名第 3 的结果. 综合来看, 本文方法无论在主观视觉效果还是在客观质量指标方面, 都具有明显的优势.

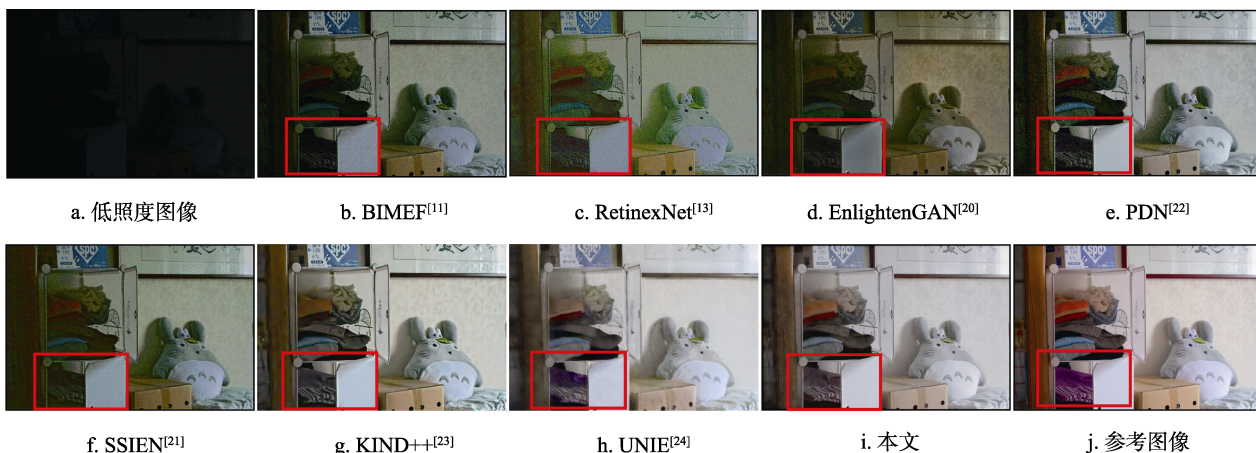


图 4 不同方法对合成图像测试结果示例 1

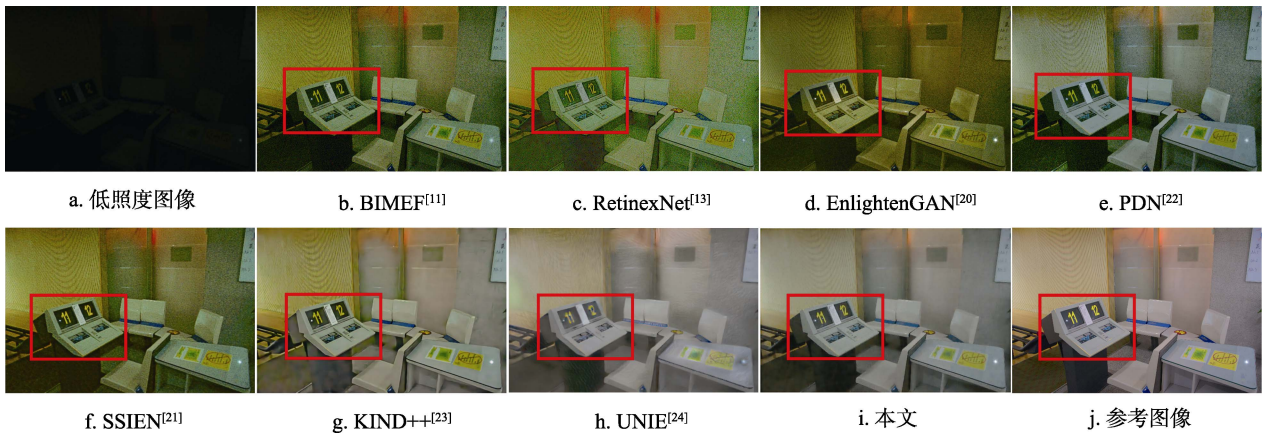


图 5 不同方法对合成图像测试结果示例 2

表 1 8 种方法在 LOL 数据集上客观评价指标比较

评价指标	BIMEF <sup>[11]</sup>	RetinexNet <sup>[13]</sup>	EnlightenGAN <sup>[20]</sup>	SSIEN <sup>[21]</sup>	PDN <sup>[22]</sup>	KIND++ <sup>[23]</sup>	UNIE <sup>[24]</sup>	本文
PSNR ↑	20.632	18.782	22.447	22.941	<u>24.486</u>	23.922	24.460	<b>26.687</b>
SSIM ↑	0.585	0.561	0.716	0.771	0.762	<u>0.881</u>	0.819	<b>0.889</b>
AB ↓	32.560	22.581	31.590	22.017	22.862	<b>12.445</b>	<u>14.624</u>	19.687
LOE ↓	1 295.275	2 201.662	1 251.696	923.341	947.159	895.555	<u>863.792</u>	<b>721.867</b>

注: 粗体表示最优值, 下划线表示次优值; ↑表示越大越好, ↓表示越小越好。

### 2.3 真实数据实验

为了验证本文方法在真实场景图像上的有效性, 分别在一幅低曝光图像和低照度图像上进行实验, 结果如图 6 和图 7 所示。

从图 6 可以看出, 6 种对比方法增强的结果在某些区域都存在增强过度或增强不足的问题, 如图中红色框内的区域所示; BIMEF, EnlightenGAN 和 PDN 这 3 种方法对树干区域的亮度增强不足, 仍然有一些细节信息被隐藏在黑暗中; RetinexNet, SSIEN 和 KIND++ 这 3 种方法则由于对图像亮度增强过度导致树干或树叶区域过亮, 出现颜色扭曲; 本文方法由于使用引导图对亮度增强程度进行调

整, 可以在增强局部较暗区域时很好地保持较亮区域的亮度, 使图像的整体亮度更加自然。

由于低照度图像是在光线比较暗的情况下获得的, 因此通常其会含有一定的噪声。从图 7 可以看出, RetinexNet, EnlightenGAN, SSIEN 和 KIND++ 这 4 种方法在对图像亮度增强的同时也放大了图像中的噪声; 本文方法在噪声抑制方面表现出最好的效果, 在增强图像整体亮度的同时也更好地恢复了图像的色彩信息, 产生了视觉上令人愉悦的结果。

### 2.4 消融实验

为了验证网络中各个组件的有效性, 本文设计了 2 个消融实验, 通过逐步添加组件的方法对结

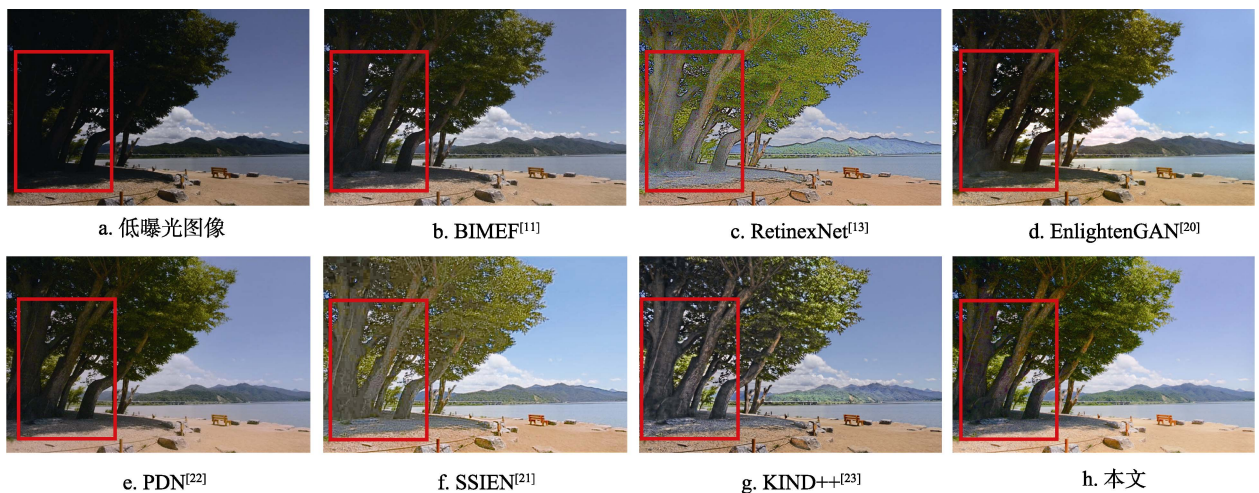


图 6 不同方法对真实场景低曝光图像测试结果

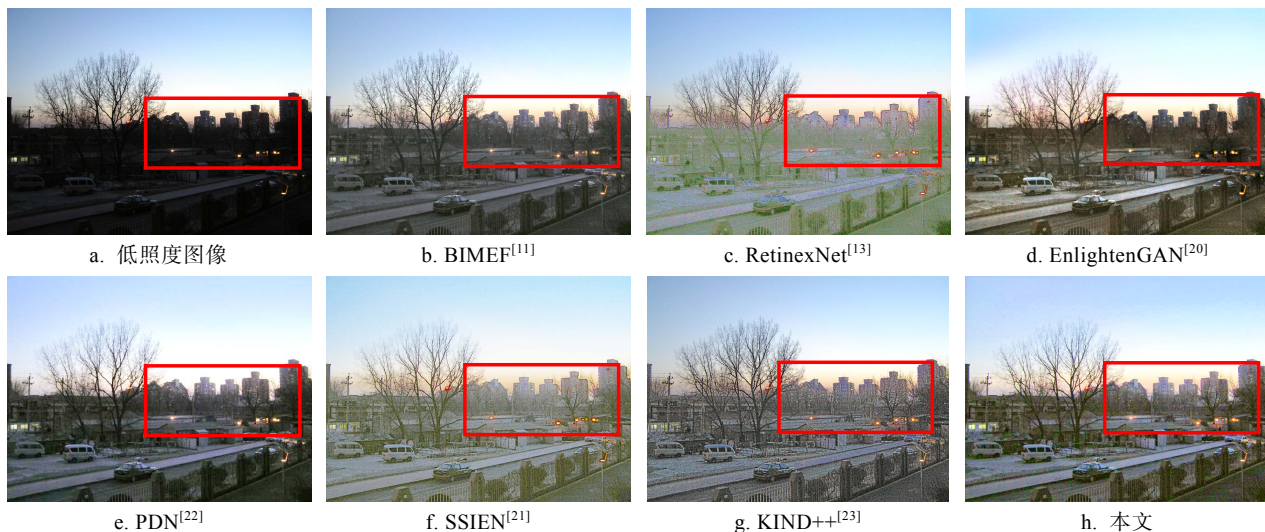


图 7 不同方法对真实场景低照度图像测试结果

果进行定性和定量比较.

(1) 引导图和直方图损失函数的消融实验

为了证明引导图和直方图损失函数在调整图像局部亮度方面的有效性, 从主客观角度进行分析, 依次训练 2 个模型: 模型 1 为同时去除引导图和直方图损失函数; 模型 2 为只去除引导图.

图 8 所示为引导图和直方图损失函数的消融实验对比. 可以看出, 引导图反映了低照度图像中不同区域的明暗程度; 模型 1 对图像进行亮度调整约束时, 低照度图像原来比较亮的区域出现了增强过度及较暗的区域增强不足的问题; 如第 1 行图像红色框内所示, 模型 2 增强的结果由于增强过度

导致灯具上纹理信息的丢失, 模型 1 的增强结果出现色彩扭曲的问题; 同样地, 在第 2 行图像红色框内, 模型 2 和模型 1 的增强结果对较暗的区域都存在增强不足问题, 同时模型 1 也出现了色彩扭曲的问题; 相比之下, 本文方法能够根据低照度图像不同区域的明暗度对增强程度进行调整, 产生的结果在亮度和色彩方面更加自然.

消融实验的定量结果如表 2 所示. 可以看出, 本文方法的 PSNR 比模型 1 的 PSNR 提升 3.877 dB, SSIM 提升 0.041; 本文方法的 PSNR 比模型 2 的 PSNR 提升 0.302 dB, SSIM 性能指标相当. 因此, 从客观指标的实验中, 证明了引导图和直方图损

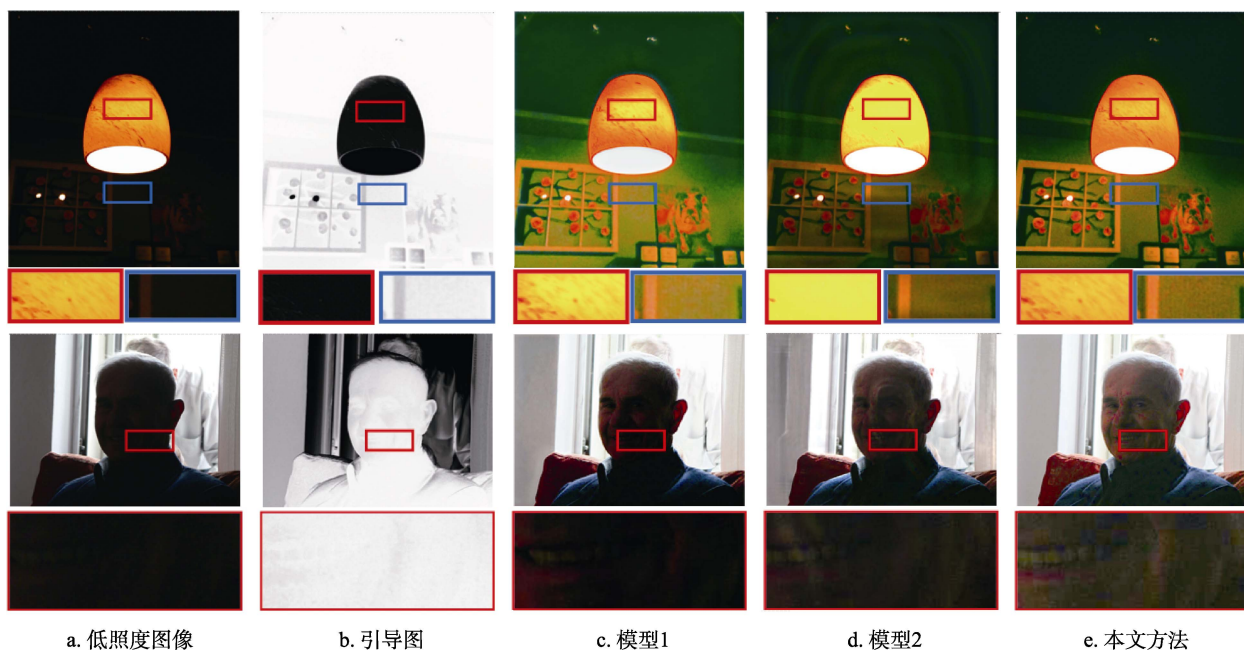


图 8 关于引导图和直方图损失的消融实验对比

表 2 引导图和直方图损失函数在 LOL 数据集上的消融实验比较

方法	引导图	直方图损失函数	PSNR/dB	SSIM
模型 1	×	×	22.806	0.843
模型 2	×	√	26.381	0.891
本文	√	√	26.683	0.884

失函数的有效性.

### (2) 数据增强消融实验

为了验证数据增强策略对网络性能的有效性, 分别在使用数据增强策略和不使用数据增强策略的情况下进行了实验. 图 9 所示为 2 种情况下 PSNR 和 SSIM 随迭代次数的变化曲线. 可以看出, 不使用数据增强策略情况下, 在初始迭代时网络性能波动比较大, 迭代到 100 次后 PSNR 出现了下降趋势, 这是由于训练样本较少出现了过拟合现象; 使用数据增强策略提高样本的数量和多样性后, 网络性能得到提升, PSNR 随着迭代次数增加仍然有上升趋势, 进一步证明了本文提出的数据增强策略的有效性.

### 2.5 目标检测实验

低照度图像增强的目的之一就是用于后续计算机视觉任务. 由于亮度比较暗, 低照度图像中的内容对计算机识别任务造成了极大的困扰, 因此进行图像增强十分必要. 为了验证本文方法在低照度条件下目标检测任务中的性能, 使用 YOLOv5 代码




图 9 数据增强消融实验对比

对 CVPR2021 UG2+挑战赛中提供的低照度图像进行增强及目标检测, 结果如图 10 所示. 第 1 行是直接对低照度图像进行目标识别的结果, 第 2 行是采用本文方法进行目标识别的结果. 可以看出, 本文方法目标检测的精度比原始低照度图像有了很大的提升, 低照度图像中检测不出的行人、自行车、摩托车等目标都能够被精确地检测出来; 通过计算, 对同一个类别, 本文方法的检测率也高于低照度图像, 如图 10 第 1 行第 1 幅图中对背包的检测率为 59%, 第 2 行中对应目标的检测率提升到了 65%; 同样的, 图 10 第 2 行第 2 幅图中对人的检测率也由低照度图像中的 64% 提升到了 75%. 本文方法可以有效地检测到原本的低照度图像检测不到的目标. 因此, 本文方法对目标检测任务的性能有很大的提升, 不仅能提高检测的准确率, 而且可实现在低照度情况下检测不到的目标物体的识别.



图 10 夜间低照度图像目标检测结果

## 3 结 语

本文提出一种照度图引导的低照度图像增强网络, 利用低照度输入图像的亮度信息构建一个照度图作为网络的注意力映射, 自适应地增强图像不同区域的亮度; 通过进一步考虑图像的边缘

信息和直方图分布差异等, 定义了一个结合边缘损失、MSE 损失和直方图损失的多元联合损失函数来约束网络的训练; 针对真实场景下获取的训练数据样本较少的问题, 为了提高网络在小样本数据上的泛化性, 提出一个概率旋转和内循环数据增强策略增加训练数据样本的数量和多样性.

在多个数据集上的实验结果表明, 本文方法能够有效、均匀地增强低照度图像的整体亮度, 并能在抑制图像中噪声的同时很好地保留图像的纹理信息, 在主观视觉质量和客观评价指标方面都优于最新的主流方法. 还讨论了所提出的低照度图像增强方法对目标检测这种高级计算机视觉任务的有效性, 证明本文方法有助于提高低照度条件下目标检测的精度.

## 参考文献(References):

- [1] Liu H L, Cao J, Wang X Y, *et al.* Study on image enhancement method for low illumination target recognition[C] //Proceedings of the Advances in Graphic Communication, Printing and Packaging Technology and Materials. Heidelberg: Springer, 2021: 155-161
- [2] Lv F F, Li Y, Lu F. Attention guided low-light image enhancement with a large scale low-light simulation dataset[J]. International Journal of Computer Vision, 2021, 129(7): 2175-2193
- [3] Lee C, Lee C, Kim C S. Contrast enhancement based on layered difference representation of 2D histograms[J]. IEEE Transactions on Image Processing, 2013, 22(12): 5372-5384
- [4] Lin S C F, Wong C Y, Rahman M A, *et al.* Image enhancement using the averaging histogram equalization (AVHEQ) approach for contrast improvement and brightness preservation[J]. Computers & Electrical Engineering, 2015, 46: 356-370
- [5] Sujee R, Padmavathi S. Image enhancement through pyramid histogram matching[C] //Proceedings of the International Conference on Computer Communication and Informatics. Los Alamitos: IEEE Computer Society Press, 2017: 1-5
- [6] Land E H. The Retinex theory of color vision[J]. Scientific American, 1977, 237(6): 108-128
- [7] Jobson D J, Rahman Z, Woodell G A. A multiscale retinex for bridging the gap between color images and the human observation of scenes[J]. IEEE Transactions on Image Processing, 1997, 6(7): 965-976
- [8] Dong X, Pang Y, Wen J T. Fast efficient algorithm for enhancement of low lighting video[C] //Proceedings of the ACM SIGGRAPH 2010 Posters. New York: ACM Press, 2010: Article No.69
- [9] Fu X Y, Zeng D L, Huang Y, *et al.* A fusion-based enhancing method for weakly illuminated images[J]. Signal Processing, 2016, 129: 82-96
- [10] Guo X J, Li Y, Ling H B. LIME: low-light image enhancement via illumination map estimation[J]. IEEE Transactions on Image Processing, 2017, 26(2): 982-993
- [11] Ying Z Q, Li G, Gao W. A bio-inspired multi-exposure fusion framework for low-light image enhancement[OL]. [2022-06-14]. <https://arxiv.org/abs/1711.00591>
- [12] Lore K G, Akintayo A, Sarkar S. LLNet: a deep autoencoder approach to natural low-light image enhancement[J]. Pattern Recognition, 2017, 61: 650-662
- [13] Wei C, Wang W J, Yang W H, *et al.* Deep retinex decomposition for low-light enhancement[OL]. [2022-06-14]. <https://arxiv.org/abs/1808.04560>
- [14] Wang L W, Liu Z S, Siu W C, *et al.* Lightening network for low-light image enhancement[J]. IEEE Transactions on Image Processing, 2020, 29: 7984-7996
- [15] Xu K, Yang X, Yin B C, *et al.* Learning to restore low-light images via decomposition-and-enhancement[C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2020: 2278-2287
- [16] Zhang Y H, Zhang J W, Guo X J. Kindling the darkness: a practical low-light image enhancer[C] //Proceedings of the 27th ACM International Conference on Multimedia. New York: ACM Press, 2019: 1632-1640
- [17] Zamir S W, Arora A, Khan S, *et al.* Multi-stage progressive image restoration[C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2021: 14816-14826
- [18] Huang G, Liu Z, Van Der Maaten L, *et al.* Densely connected convolutional networks[C] //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2017: 2261-2269
- [19] Woo S, Park J, Lee J Y, *et al.* CBAM: convolutional block attention module[C] //Proceedings of the 15th European Conference on Computer Vision. Heidelberg: Springer, 2018: 3-19
- [20] Jiang Y F, Gong X Y, Liu D, *et al.* EnlightenGAN: deep light enhancement without paired supervision[J]. IEEE Transactions on Image Processing, 2021, 30: 2340-2349
- [21] Zhang Y, Di X G, Zhang B, *et al.* Self-supervised image enhancement network: training with low light images only[OL]. [2022-06-14]. <https://arxiv.org/abs/2002.11300>
- [22] Huang Shuying, Hu Wei, Yang Yong, *et al.* A low-exposure image enhancement based on progressive dual network model[J]. Chinese Journal of Computers, 2021, 44(2): 384-394 (in Chinese)  
(黄淑英, 胡威, 杨勇, 等. 基于渐进式双网络模型的低曝光图像增强方法[J]. 计算机学报, 2021, 44(2): 384-394)
- [23] Zhang Y H, Guo X J, Ma J Y, *et al.* Beyond brightening low-light images[J]. International Journal of Computer Vision, 2021, 129(4): 1013-1037
- [24] Jin Y Y, Yang W H, Tan R T. Unsupervised night image enhancement: when layer decomposition meets light-effects suppression[C] //Proceedings of the 17th European Conference on Computer Vision. Heidelberg: Springer, 2022: 404-421
- [25] Chen Z Y, Abidi B R, Page D L, *et al.* Gray-level grouping (GLG): an automatic method for optimized image contrast Enhancement-part I: the basic method[J]. IEEE Transactions on Image Processing, 2006, 15(8): 2290-2302
- [26] Yeganeh H, Wang Z. Objective quality assessment of tone-mapped images[J]. IEEE Transactions on Image Processing, 2013, 22(2): 657-667
- [27] Dang-Nguyen D T, Pasquini C, Conotter V, *et al.* RAISE: a raw images dataset for digital image forensics[C] //Proceedings of the 6th ACM Multimedia Systems Conference. New York: ACM Press, 2015: 219-224