

基于Retinex理论的低照度图像自适应增强算法

郑涤尘, 何继开, 刘艺, 高帆, 张登银

引用本文

郑涤尘, 何继开, 刘艺, 高帆, 张登银. 基于Retinex理论的低照度图像自适应增强算法[J]. 计算机科学, 2025, 52(10): 168-175.

ZHENG Dichen, HE Jikai, LIU Yi, GAO Fan, ZHANG Dengyin. [Low Light Image Adaptive Enhancement Algorithm Based on Retinex Theory](#) [J]. Computer Science, 2025, 52(10): 168-175.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于双流深度学习的Dockerfile安全误配置检测方法](#)

Dual-stream Feature Fusion Approach for Dockerfile Security Misconfiguration Detection

计算机科学, 2025, 52(10): 395-403. <https://doi.org/10.11896/jsjcx.241000014>

[基于DS理论的多模态信息抽取方法](#)

Multimodal Information Extraction Fusion Method Based on Dempster-Shafer Theory

计算机科学, 2025, 52(10): 208-216. <https://doi.org/10.11896/jsjcx.240200081>

[基于神经辐射场的即时高保真人脸生成算法](#)

Immediate Generation Algorithm of High-fidelity Head Avatars Based on NeRF

计算机科学, 2025, 52(10): 159-167. <https://doi.org/10.11896/jsjcx.241000066>

[基于雷达和视觉融合的多模态空中手写体识别](#)

Multimodal Air-writing Gesture Recognition Based on Radar-Vision Fusion

计算机科学, 2025, 52(9): 259-268. <https://doi.org/10.11896/jsjcx.240400143>

[数据分类分级技术研究综述](#)

Survey of Data Classification and Grading Studies

计算机科学, 2025, 52(9): 195-211. <https://doi.org/10.11896/jsjcx.240800149>

基于 Retinex 理论的低照度图像自适应增强算法

郑涤尘¹ 何继开¹ 刘艺² 高帆¹ 张登银²

¹ 南京邮电大学通信与信息工程学院 南京 210003

² 南京邮电大学物联网学院 南京 210003

(1425234019@qq.com)

摘要 现实环境中图像通常在次优照明条件下拍摄,导致亮度不足、观感较差。现有低照度图像增强方法往往结构复杂,侧重于改善暗光区域的可视度,但可能过度增强图像的明亮区域,放大隐藏的噪声。多数基于 Retinex 理论的方法存在噪点过多、细节损失和颜色失真等问题,影响增强结果的视觉质量。为了解决该问题,提出了一种基于 Retinex 理论的低照度图像自适应增强算法,旨在有效提升图像亮度的同时真实、自然地还原图像。首先,低照度图像经过投影模块去除不适合 Retinex 理论分解的噪声;其次,分解网络将图像分解为照度分量和反射分量;最后,照度分量经过自适应迭代曲线进行调整,与反射分量相乘得到增强图像。实验结果表明,相比于其他主流算法,所提算法在客观评价指标特别是 PSNR 和 SSIM 上优势明显:在 LOL 数据集上分别达到 19.98dB 和 0.76,较次优算法提高 4.9% 和 4.1%;在 LSRW 数据集上分别达到 18.94dB 和 0.58,较次优算法提高 1.5% 和 7.4%。在有参考数据集和无参考数据集上,所提算法得到的增强图像的亮度均有显著提升,色彩真实自然,主观视觉效果更好。

关键词: 图像增强;低照度;Retinex;迭代增强;深度学习

中图分类号 TP391

Low Light Image Adaptive Enhancement Algorithm Based on Retinex Theory

ZHENG Dichen¹, HE Jikai¹, LIU Yi², GAO Fan¹ and ZHANG Dengyin²

¹ School of Communication and Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

² School of Internet of Things, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

Abstract Images in real-world environments are often shot under sub-optimal lighting conditions, resulting in insufficient brightness and poor visual experience. Existing low-light image enhancement methods are often complex in structure and focus on improving the visibility of dark areas, but may over-enhance the bright areas of the image and amplify hidden noise. Most methods based on Retinex theory have problems such as excessive noise, loss of details and color distortion, which affect the visual quality of the enhancement results. In order to solve this problem, this paper proposes a low-light image adaptive enhancement algorithm based on Retinex theory, which aims to effectively improve the brightness of the image while restoring the image truly and naturally. Firstly, the low-light image is passed through the projection module to remove noise that is not suitable for Retinex decomposition. Secondly, the decomposition network decomposes the image into an illumination component and a reflection component. Finally, the illumination component is adjusted through an adaptive iterative curve and multiplied with the reflection component to obtain an enhanced image. Experimental results show that compared with other mainstream algorithms, the proposed algorithm has obvious advantages in objective evaluation indicators, especially PSNR and SSIM: tests on the LOL dataset show that PSNR and SSIM reach 19.98dB and 0.76, respectively, which are 4.9% and 4.1% higher than the suboptimal algorithm; tests on the LSRW dataset show that PSNR and SSIM reach 18.94dB and 0.58, respectively, which are 1.5% and 7.4% higher than the suboptimal algorithm. On both of the referenced dataset and the non-reference dataset, the brightness of the enhanced image obtained by the proposed algorithm is significantly improved, the colors are more realistic and natural, and the subjective visual effect is better.

Keywords Image enhancement, Low-light, Retinex, Iterative enhancement, Deep learning

到稿日期:2024-08-09 返修日期:2024-10-13

基金项目:国家自然科学基金(61872423)

This work was supported by the National Natural Science Foundation of China(61872423).

通信作者:张登银(zhangdy@njupt.edu.cn)

1 引言

在光照条件不理想的情况下,受照明不良、光束角度不当等环境因素和 ISO 小、曝光时间短等技术限制影响,到达传感器的光子不足,图像特征恶化、对比度低,这类图像称为低照度图像。低照度图像不仅降低了图像的感知质量,还影响了目标检测^[1]、图像识别^[2]和语义分割^[3]等后续高级视觉任务的性能,因此,对低照度图像进行增强具有重要的研究意义和应用价值。

传统方法主要分为两类:一类基于直方图均衡化^[4]来增强图像的亮度和对比度;另一类引入 Retinex 理论^[5]构建模型,假设人类观察的图像可分解为照度图和反射图,并改变照度图像素的动态范围来增强对比度。传统方法通常有局限性,例如假设过于理想导致细节丢失和色彩扭曲、难以找到准确先验,以及优化过程复杂等。相比传统方法,基于深度学习的解决方案具备更优准确性、鲁棒性和更快的计算速度。Lore 等^[6]提出一种图像对比度增强和去噪的堆叠稀疏去噪自动编码器变体,开创了低照度图像增强深度学习解决方案的先河。RetinexNet^[7]将 Retinex 理论与 CNN 结合来估计和调整照度图以实现图像增强,包括分解图像为反射图和平滑照度图的 DecomNet 模块,以及调整照度图实现低光增强的 EnhanceNet 模块,并利用 BM3D 进行去噪处理。Zhang 等^[8]用 3 个子网络进行图层分解、反射图恢复和照度图调整,称为 KinD,后续利用多尺度光照注意力模块缓解结果中的视觉缺陷,称为 KinD++^[9]。RUAS^[10]利用 Retinex 理论进行神经网络结构搜索,结合先验约束寻求增强图像的最优解。RetinexDIP^[11]通过随机采样的白噪声生成输入图像的反射分量和照度分量,使用 Retinex 模型来增强低照度图像。R2Rnet^[12]根据 Retinex 理论分解图像得到空间信息提高对比度,并基于傅里叶变换提取频域信息修复图像细节。

上述网络大多基于 Retinex 理论增强图像,另一类具有代表性的方法则基于曲线估计迭代增强图像。Zhang 等^[13]提出一种背光图像修复的 ExCNet,通过估计最适合背光图像曝光的“S 曲线”来调整图像亮度。Guo 等^[14]提出了 ZeroDCE 模型,将光增强视为一项针对图像的曲线估算任务,将低光图像作为输入,并产生高阶曲线作为输出。Zhu 等^[15]提出一种三分支卷积神经网络 RRDNet,通过显式的噪声预测来去噪并恢复曝光不足的图像。SGZ^[16]提出了一种语义引导的低照度增强网络,在提高图像亮度的同时保留了语义信息。Self-DACE^[17]设计了新颖的调整曲线,在处理复杂光照环境下的图片时,能减少过度曝光现象,并通过去噪网络消除黑暗中的噪声。

在 Retinex 理论和曲线估计之外,Jiang 等^[18]提出一种基于 GAN 的低光图像增强网络 EnlightenGAN,采用注意力引导的 U-Net^[19]作为生成器,并使用全局-局部判别器确保增强图像更加真实。SCI^[20]引入了一种自校准照明框架,该框架

利用具有权重共享的级联结构学习照明增强过程。IAT^[21]提出了一种用于曝光校正和图像增强的照明自适应 Transformer 结构来模拟相机摄影的图像处理流程,并调整流程中的关键参数来动态提升图像亮度。CDAN^[22]利用卷积密集注意力引导网络缓解曝光不足并恢复了细节信息。Lighten-Diffusion^[23]提出一种基于扩散的可学习无监督框架,将 Retinex 理论与扩散模型相结合来学习不同场景下低照度图像的退化模式并恢复正常光图像,但需要大量低照度图像进行训练。CoLIE^[24]根据局部上下文将低照度图像的二维坐标映射到其照明分量来重新定义增强过程,并利用隐式神经函数结合嵌入式引导滤波器在 HSV 空间内重建增强光图像。FMR-Net^[25]提出用于低照度图像增强的快速多尺度残差网络,通过叠加优化的残差块和设计分支结构快速完成特征提取和图像推理,较好地提升了图像的亮度和对比度。

尽管现有的低照度图像增强算法取得了不错的效果,但仍存在一些问题。基于 Retinex 理论的算法^[26]通常网络结构复杂、泛化能力差,基于曲线估计的算法往往亮度增强不足或过度放大图像噪声,而其他算法也存在训练困难、颜色失真等问题。为此,本文设计了一种基于 Retinex 理论的低照度图像自适应增强网络 RAIC,主要贡献包括:

1)设计了一种基于 Retinex 理论的低照度图像分解网络,网络仅由卷积、残差连接和通道注意力等简单有效的结构组成,同时引入投影模块来移除不适当的噪声,确保网络稳定准确地分解图像。

2)设计了一种利用自适应迭代曲线的增强网络来调整照度分量,结合基于相对信息的损失函数使网络更加注重颜色和结构等信息,缓解了低照度图像增强任务一对多的不适应问题。

3)在多个无参考数据集和有参考数据集上进行了实验,验证了 RAIC 的泛化能力,并且增强图像真实自然,在主观与客观评价上较其他算法有明显优势。

2 基于 Retinex 理论的低照度图像自适应增强网络

本文设计了一种基于 Retinex 理论的低照度图像自适应增强网络 RAIC,其整体结构如图 1 所示。训练过程分两阶段进行:第一阶段分解网络,包含投影模块 Projection Module (PM)、照度分量模块 Illumination Module (LM) 和反射分量模块 Reflectance Module (RM);第二阶段增强网络,包含调整因子提取模块 Adjustment Factor Extraction Module (AFEM) 和自适应迭代曲线 Adaptive Iteration Curve (AIC)。第一阶段利用曝光程度不同的低照度图像对训练分解网络,训练完成的分解网络可以由低照度图像得到照度分量和反射分量。第二阶段训练仅需第一阶段输入的低照度图像对中的任意一张,并使其经过已训练完成的分解网络得到照度分量和反射分量,照度分量经过增强网络进行调整后与反射分量逐元素相乘,得到最终的增强图像。

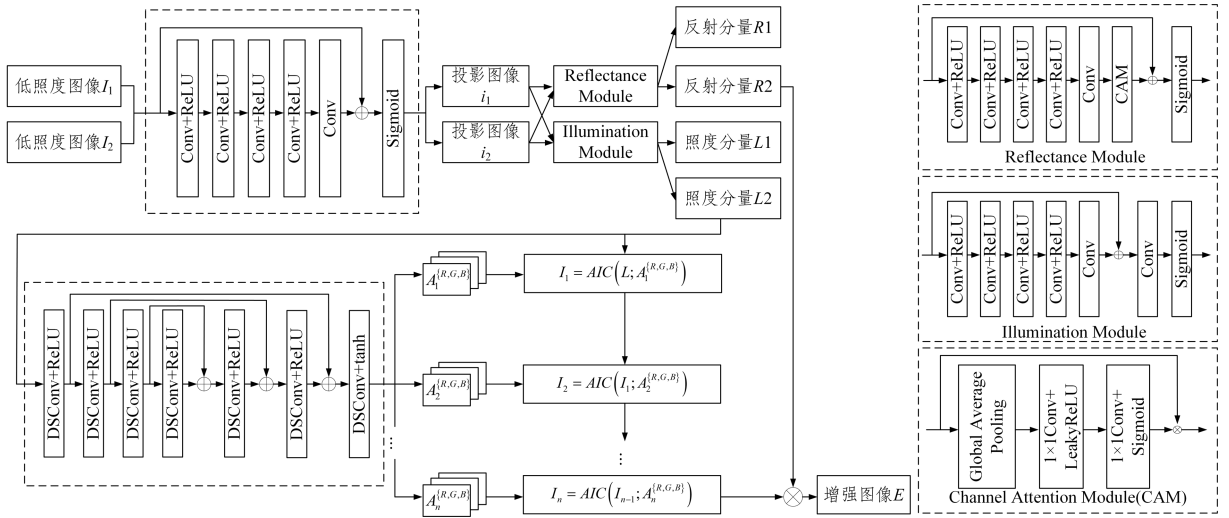


图1 RAIC网络结构

Fig. 1 Network architecture of RAIC

2.1 分解网络

本文设计的分解网络通过构建照度分量模块 LM 和反射分量模块 RM 来基于 Retinex 理论分解低照度图像。LM 主要由 3×3 的卷积层构成,前 4 个卷积层使用 ReLU 激活函数,第 5 个卷积层的输出与输入 LM 的图像进行残差连接,以减少梯度消散并提高网络性能。根据 Retinex 理论,假设 R, G, B 3 个颜色通道具有相同的照度分量,则 LM 使用第 6 个卷积层将输出结果的通道数转换为 1。LM 以 Sigmoid 层作为结束,将输出标准化到 $[0, 1]$ 。RM 的结构与 LM 类似,只是将第 5 个卷积层的输出送入通道注意力模块(Channel Attention Module, CAM),再与输入 RM 的图像进行残差连接。此外, RM 输出结果的通道数为 3,与输入保持一致。

通道注意力模块由全局平均池化和两个 1×1 的卷积层构成,沿通道维度生成注意力图,并与输入的特征图逐元素相乘,实现跨通道间的信息交互。

在基于 Retinex 理论对图像进行分解时通常不会考虑噪声因素,但实际的低照度图像并不是理想的无噪声图像。为了保证能够准确地分解图像,受 Fu 等^[27]的启发,本文引入了投影模块 PM 来将原始的低照度图像转换为适合分解的投影图像,其结构与 LM 类似,只是输出通道数为 3。PM 的作用可以从误差重分配的角度来解释,分解图像时的目标函数可以表示为:

$$\begin{aligned} \arg \min_{L,R} \| I - L \cdot R - \epsilon \| &= \arg \min_{L,R} \| I - i + i - L \cdot R - \epsilon \| \\ &\leq \| I - i - \epsilon \| + \arg \min_{L,R} \| i - \\ &L \cdot R \| \end{aligned} \quad (1)$$

其中, I 表示原始低照度图像, i 表示投影图像, ϵ 表示由噪声因素构成的误差, L 和 R 分别表示分解得到的照度分量和反射分量。由式(1)可知,分解过程会受到无法建模表示的误差的影响,而 PM 对图像进行投影预处理,将误差从分解阶段转移到了投影阶段,在保持投影后图像与原始图像高度相似的同时移除了不适当的噪声,使目标函数更符合理想状态下的 Retinex 分解任务。图 2 给出了原始低照度图像、投影图像和二者的差分图像,噪声因素在投影过程中被移除,并且差分图

像的像素值越小,意味着投影图像和原始图像越接近。



图2 原始低照度图像的投影预处理

Fig. 2 Projection preprocessing of original low-light images

2.2 增强网络

本文设计的增强网络旨在调整照度分量,参考低照度图像循环增强^[28]和深度曲线估计^[14]的思想,构建了调整因子提取模块 AFEM 和自适应迭代曲线 AIC 来实现增强目标。AFEM 是为了获取图像的局部照度信息并记录下来以供 AIC 进行自适应调整。AFEM 是一个具有跳跃连接类 U-Net 结构,可以处理任意大小的输入图像,其卷积块都由深度可分离卷积^[29]和 ReLU 函数组成。最后一个卷积块通过 Tanh 函数得到调整因子。调整因子提取完成后,将送入自适应迭代曲线 AIC,作为一类可学习参数,参与照度分量的迭代增强过程。

自适应迭代曲线 AIC 应该满足两个要求:1)为了保证像素之间的对比度,函数应当保持单调;2)为了便于网络反向传播,函数应当简单且可微。AIC 可由二次函数表示为:

$$I_n(x) = I_{n-1}(x) + A_n(x)(I_{n-1}^2(x) - I_{n-1}(x)) \quad (2)$$

其中, $A_n(x)$ 表示 AFEM 提取的调整因子,与输入图像的大小保持一致, $I_n(x)$ 表示 AIC 第 n 次迭代的调整图像, $I_{n-1}(x)$ 表示 AIC 第 $n-1$ 次迭代的调整图像。

图 3 展示了自适应迭代曲线在调整图像亮度方面的灵活性和泛用性。对图像像素进行归一化后,当调整因子越接近 -1 时,对强度较低的像素的提升越明显,经过多次迭代能够显著提升较暗区域的亮度;当调整因子越接近 0 时,对所有强度的像素的提升越不明显,可以避免较亮区域被过度曝光。因此通过 AFEM 获取图像不同局部的调整因子,实现不同明暗区域的自适应增强,可以在提升图像整体亮度的同时减少局部提升不足或过度的问题。




图3 不同调整因子的自适应迭代曲线

Fig. 3 AIC with different adjustment factors

2.3 损失函数

2.3.1 第一阶段损失函数

第一阶段分解网络使用投影损失^[27] L_P 、反射一致性损失 L_C 和 Retinex 先验约束构成的损失 L_R , 将低照度图像分解为照度分量和反射分量。

1) 投影损失 L_P : 投影损失指导 PM 将误差从分解阶段转移到投影阶段, 从而移除不适当的噪声, 可以表示为:

$$L_P = \|I - i\|_2^2 \quad (3)$$

2) 反射一致性损失 L_C : Retinex 理论假设低照度图像对共享相同的物理属性, 因此 L_C 可以使网络预测相同的反射分量, 可以表示为:

$$L_C = \|R_1 - R_2\|_2^2 \quad (4)$$

其中, R_1 和 R_2 表示低照度图像对的反射分量。

3) Retinex 先验约束损失 L_R : 式(5)中, 第一项和第二项根据 Retinex 理论来指导网络分解, 第一项确保分解后的分量能够满足重建图像的要求, 第二项在得到照度分量后根据 Retinex 理论进行元素相除得到反射分量来指导 RM 分解, 后两项则对照度分量施加平滑和初始化的先验。

$$L_R = \|R \cdot L - i\|_2^2 + \|R - i/L\|_2^2 + \|L - L_0\|_2^2 + \|\nabla L\|_1 \quad (5)$$

其中, L_0 表示照度分量的初始估计, 通过计算 R, G, B 通道的最大值获取, ∇ 表示水平和垂直梯度。

第一阶段损失函数由权重 $\omega_0, \omega_1, \omega_2$ 加权表示为:

$$L_{\text{stage1}} = \omega_0 L_P + \omega_1 L_C + \omega_2 L_R \quad (6)$$

2.3.2 第二阶段损失函数

第二阶段增强网络使用 L1^[30]、SSIM^[31] 损失、颜色损失^[32] L_{col} , 以及基于像素块相对信息的亮度损失^[33] L_{bri} 和结构损失^[33] L_{stru} , 来调整照度分量并提高增强图像的视觉效果。

1) 颜色损失 L_{col} : 为了指导网络匹配增强图像和参考图像之间的颜色信息, 采用余弦相似度来衡量两个像素之间的色调及饱和度差异, 可以表示为:

$$L_{\text{col}} = 1 - \sum_{i=1, j=1}^{m, n} \langle E_{(i,j)}, H_{(i,j)} \rangle \quad (7)$$

其中, $E_{(i,j)}$ 和 $H_{(i,j)}$ 表示增强图像和参考图像第 i 行、第 j 列像素, $\langle \cdot \rangle$ 表示两个向量的余弦相似度。

2) 亮度损失 L_{bri} : 增强图像和参考图像应该具有相同的亮度顺序^[34], Zhang 等^[33] 据此设计了亮度损失函数, 可以表示为:

$$L_{\text{bri}} = 1 - \sum_{c \in R, G, B} \sum_{i=1, j=1}^{m, n} \langle b(E_{(i,j)}^c) - \min(b(E_{(i,j)}^c)), b(H_{(i,j)}^c) - \min(b(H_{(i,j)}^c)) \rangle \quad (8)$$

其中, c 表示 3 个颜色通道, $b(E_{(i,j)})$ 和 $b(H_{(i,j)})$ 表示以像素 $E_{(i,j)}$ 和 $H_{(i,j)}$ 为中心的像素块。

3) 结构损失 L_{stru} : 结构信息通常使用梯度表示, Zhang 等^[33] 利用梯度代替 L_{bri} 中的亮度信息, 减少了增强过程中亮度线性变化导致的饱和度问题, 可以表示为:

$$L_{\text{stru}} = 1 - \sum_{c \in R, G, B} \sum_{i=1, j=1}^{m, n} \langle b(\nabla E_{(i,j)}^c) - \min(b(\nabla E_{(i,j)}^c)), b(\nabla H_{(i,j)}^c) - \min(b(\nabla H_{(i,j)}^c)) \rangle \quad (9)$$

第二阶段损失函数由权重 $\omega_3, \omega_4, \omega_5$ 加权表示为:

$$L_{\text{stage2}} = L_1 + L_{\text{SSIM}} + \omega_3 L_{\text{col}} + \omega_4 L_{\text{bri}} + \omega_5 L_{\text{stru}} \quad (10)$$

3 实验结果及分析

3.1 实验环境及数据集

本文提出的 RAIC 在搭载 NVIDIA GTX 1660Ti GPU 和 Intel^(R) Xeon^(R) Silver 4114 CPU 的服务器上使用 PyTorch 框架进行训练。训练所用数据收集自 LOL^[7] 数据集和 SICE^[35] 数据集。LOL 数据集首次在真实场景拍摄中包含低光和正常光配对图像; SICE 数据集包含室内和室外场景下的多重曝光图像序列, 每个序列包含 3 到 18 张不同曝光度的低对比度图像。随机选取 LOL 和 SICE 训练集中正常曝光的参考图像和对应的曝光不足且对齐良好的 1200 张低照度图像来构建训练集。第一阶段输入的低照度图像对随机裁剪为 128×128 像素, 训练批量大小为 8, 使用初始学习率为 1×10^{-4} 的 Adam 优化器, 迭代次数设置为 300, 损失函数权重为 100, 1, 1。第二阶段训练批量大小为 8, 使用初始学习率为 1×10^{-4} 的 Adam 优化器, 迭代次数设置为 300, 损失函数权重均为 1。

为了验证 RAIC 的性能, 本文在无参考公开数据集 DICM^[36], LIME^[37], MEF^[38], NPE^[39] 和有参考公开数据集 LOL 和 LSRW^[12] 上进行测试, 并从定性比较和定量比较两方面进行分析。

本文对比的近年来的主流算法包括: RetinexNet^[7], ZeroDCE^[14], RUAS^[10], EnlightenGAN^[18], SCI^[20], PairLIE^[27], R2Rnet^[12], Self-DACE^[17]。

3.2 实验评估及结果比较

3.2.1 无参考数据集实验

本文在 DICM, LIME, MEF, NPE 数据集上对 RAIC 和其他主流算法进行测试, 由于这些数据集仅包含低照度图像, 因此适合使用主观评价指标进行定性分析和定量分析。

本文邀请了 6 位测试人员对各算法的增强结果进行打分, 分值由 0 到 10 分别对应增强效果由差到好。表 1 列出了各算法增强结果的主观得分情况, 粗体和下划线分别表示最优和次优结果。RAIC 在 DICM, MEF, NPE 这 3 个数据集上均取得了最优评分, 在 LIME 数据集上取得了次优评分。在无参考图像的评价指标上, 选择自然图像质量评估 NIQE^[40] 来衡量低照度图像增强的效果。NIQE 提取待测图像的特征, 并利用多元高斯模型来计算待测图像与预先建立的模型之间的差异, 计算结果反映图像的失真程度, 其值越小则表明待测图像越接近真实视觉效果。表 2 列出了各算法增强结果的 NIQE 指标, 粗体和下划线分别表示最优和次优结果。RAIC 在 DICM 和 LIME 数据集上均取得了最优结果, 分别比次优算法降低 0.06, 0.085; 在 NPE 数据集上取得了次优结果, 比最优算法高出 0.09; 在 MEF 数据集上取得了第三的

结果,分别比次优算法和最优算法高出 0.05, 0.124。尽管 RAIC 没有在 4 个数据集上都取得最优结果,但整体仍然取得了不错的结果,较次优算法降低 0.032,且在未取得最优结果的数据集上与其他最优算法的差距不大,这表明 RAIC 具备一定的保持图像真实性和自然性的能力,并且仍有改进空间。

表 1 在无参考数据集上的评分对比

Table 1 Comparison of scores on non-reference datasets

方法	DICM	LIME	MEF	NPE
RetinexNet	6.92	6.38	6.88	7.26
Zero-DCE	7.55	8.25	7.98	7.40
RUAS	6.12	6.25	6.63	6.55
EnGAN	7.23	7.45	8.02	7.38
SCI	7.43	7.87	7.84	7.18
PairLIE	<u>8.03</u>	7.98	<u>8.22</u>	7.68
R2RNet	7.88	6.97	7.83	7.52
Self-DACE	7.27	7.46	8.05	<u>7.73</u>
RAIC	8.12	8.07	8.41	7.82


表 2 在无参考数据集上的 NIQE 指标

Table 2 NIQE indicator on non-reference datasets

方法	DICM	LIME	MEF	NPE	Average
RetinexNet	4.152	3.725	3.881	3.978	3.934
Zero-DCE	3.357	<u>3.556</u>	3.612	3.947	3.618
RUAS	4.107	4.412	4.234	6.928	4.920
EnGAN	3.405	3.606	3.913	3.951	3.719
SCI	4.893	3.988	3.863	4.762	4.377
PairLIE	3.395	3.575	3.686	3.642	3.575
R2RNet	3.762	3.885	4.619	3.917	4.046
Self-DACE	<u>3.291</u>	3.811	3.865	4.113	3.770
RAIC	3.231	3.471	3.736	<u>3.732</u>	3.543

图 4 给出了各算法对测试图像的增强结果,图像的亮度均得到了提升,但多数方法在色彩、噪声和细节等视觉效果上不能令人满意。RetinexNet 亮度提升较为明显,但颜色和

纹理失真严重,颜色饱和度过高,图像整体较为模糊;Zero-DCE 增强亮度不足,图像整体偏暗,并且较暗区域增强后出现噪声;RUAS 增强结果过曝严重,对天空等较亮区域增强后细节完全丢失,整体效果较差;EnlightenGAN 增强结果有明显的色彩偏差,对人脸、树木等区域亮度提升有限,并且在灯光区域有明显的光晕;SCI 在天空等较亮区域增强过度,曝光现象明显,而对人物、气球等较暗区域亮度提升有限;PairLIE 色彩恢复较为真实,纹理失真少,但整体亮度提升仍有不足;R2RNet 增强结果亮度偏高,并且颜色失真较为严重;Self-DACE 存在一定的色彩偏差,对于天空中云朵等细节的恢复存在丢失现象。在对比算法中,RetinexNet 和 R2RNet 没有对图像中隐藏的噪声进行预处理或单独建模,而是直接根据理想状态的 Retinex 理论进行分解;Zero-DCE 和 Self-DACE 无法利用低照度图像对应的参考图像的信息,并且其损失函数并非全部为低照度图像增强任务而设计;RUAS 通过搜索空间架构优化网络光照估计和降噪结构,达到了较好抑制噪声的效果,但泛化能力弱且对光照良好的区域往往过度增强;EnlightenGAN 缺乏有效的物理规律的建模,对图像的增强效果不均匀,增强结果中仍可能存在阴影区域;SCI 利用具有权重共享的级联自校准照明学习模块加速算法并减少参数,但并未对不均匀光照进行纠正;PairLIE 仅针对 Retinex 分解过程进行了训练,而在亮度提升部分则需要根据不同图像人为确定合适的提亮因子。上述各算法的不足导致增强结果不尽如人意。本文所提的 RAIC 增强测试图像后亮度提升显著,不存在明显的光晕、颜色偏差和纹理失真现象,整体视觉效果良好。结合表 1、表 2 的定量分析和图 4 的定性分析可知,RAIC 在有效提升图像亮度和真实自然地还原图像两方面取得了较好平衡,优于对比的其他主流算法。



注:图中 Retinex, ZDCE, EnGAN, SDACE 分别表示 RetinexNet, Zero-DCE, EnlightenGAN, Self-DACE。

图 4 在无参考数据集上的测试结果

Fig. 4 Test results on non-reference datasets

3.2.2 有参考数据集实验

本文在 LOL 测试集上对 RAIC 和其他主流算法进行测试,并对增强结果进行定量分析,分析指标包括峰值信噪比 PSNR^[41]、结构相似性 SSIM^[31] 和学习感知图像块相似度 LPIPS^[42]。PSNR 从全局衡量增强图像与参考图像的失真程度,其值越大则相似度越高。SSIM 注重亮度、对比度和结构信息,其值越高则增强图像质量越好。LPIPS 通

过预训练的深度学习模型来评估增强结果与对应参考图像之间的感知相似性,其值越低说明两张图片越相似。图 5 展示了各算法的增强结果,对比可知,RAIC 在显著提升低照度图像整体亮度的同时避免了颜色失真和细节丢失,边缘纹理真实自然,噪声较少,视觉效果良好。

为了验证 RAIC 的泛化能力,本文还在 LSRW 数据集上进行了测试。由图 6 可知,RAIC 在增强低照度图片整体

亮度的同时,兼顾了伞下阴影等较暗区域和天空等较亮区域,视觉效果优于其他算法,证明了其泛化能力和鲁棒性能良好。

表 3 列出了各算法在有参考数据集上的指标对比,粗体和下划线分别表示最优和次优结果。RAIC 在 LOL 和 LSRW 这两个数据集上均取得了最优的 PSNR 指标和 SSIM 指标,分别达到 19.98dB,18.94dB 和 0.76,0.58,相较于次优

算法的 19.05dB,18.67dB 和 0.73,0.54 分别提升了 4.9%,1.5%和 4.1%,7.4%。在 LPIPS 指标上,RAIC 在两个数据集上均取得了次优结果 0.231 和 0.387,且与最优结果的 0.212 和 0.367 相差不大。结合图 5、图 6 增强图像的视觉效果和表 3 的评价指标可知,RAIC 在主观和客观分析上对比其他算法均具有明显优势。



图 5 在 LOL 数据集上的测试结果
Fig. 5 Test results on LOL dataset




图 6 在 LSRW 数据集上的测试结果
Fig. 6 Test results on LSRW dataset

表 3 在有参考数据集上的评价指标对比

Table 3 Comparison of evaluation indicators on reference datasets

方法	LOL 数据集			LSRW 数据集		
	PSNR	SSIM	LPIPS	PSNR	SSIM	LPIPS
RetinexNet	16.77	0.46	0.474	16.81	0.38	0.471
Zero-DCE	14.86	0.56	0.335	16.40	0.47	0.367
RUAS	16.40	0.50	0.272	15.73	0.49	0.525
EnGAN	17.48	0.65	0.322	15.93	0.48	0.405
SCI	14.78	0.52	0.343	15.69	0.43	0.399
PairLIE	18.74	0.72	0.243	<u>18.67</u>	0.53	0.437
R2RNet	18.13	0.71	0.286	17.25	<u>0.54</u>	0.396
Self-DACE	<u>19.05</u>	<u>0.73</u>	0.212	18.53	0.52	0.418
RAIC	19.98	0.76	<u>0.231</u>	18.94	0.58	<u>0.387</u>

3.3 消融实验

为了确定网络各部分的作用,本文设计了 6 组消融实验,设置 A 去除了 PM 模块和损失函数 L_P ,设置 B 去除了损失函数 L_C ,设置 C 去除了损失函数 L_R ,设置 D 去除了损失函数 L_{stru} ,设置 E 去除了损失函数 L_{bri} ,设置 F 去除了损失函数 L_{col} 。结合图 7 和表 4 的评价指标可知,设置 A 中 PM 和 L_P 能够协助网络进行更稳定的 Retinex 分解,缺少 PM 和 L_P 会使网络将原始图像中隐藏的噪声纳入建模过程进行分解,导致图像增强结果出现“泛绿”现象,颜色失真较为严重。




图 7 消融实验对比

Fig. 7 Comparison results of ablation experiments

设置 B 缺少 L_C 导致网络无法预测相同的反射分量, 图像增强结果颜色出现偏差,并且在橱窗等位置出现大量

噪声、部分区域过曝明显, PSNR, SSIM, LPIPS 指标大幅降低。设置 C 缺少 L_R 导致 PSNR, SSIM, LPIPS 指标严重下降, 增强图像的视觉效果差、颜色信息几乎完全丢失, 这是因为 Retinex 分解需要一些先验约束来初始化和抑制照度分量。设置 D、设置 E、设置 F 中的损失函数 L_{stru} 、损失函数 L_{bri} 和损失函数 L_{col} 能够帮助网络更好地去除噪声和保留结构信息, 更加有效地提升图像的整体亮度, 其中 L_{stru} 可以减少增强过程中亮度线性变化引起的过饱和与欠饱和的影响, L_{bri} 要求增强图像与无噪声参照图像在每个图像块中具有相同的亮度顺序从而抑制噪声, 而 L_{col} 鼓励网络匹配增强图像和参考图像之间的色调与饱和度信息, 显著提高了 PSNR, SSIM, LPIPS 评价指标。

表 4 消融实验指标对比

Table 4 Comparison of indicators of ablation experiments

消融实验	PSNR	SSIM	LPIPS
设置 A	19.02	0.70	0.283
设置 B	16.37	0.59	0.404
设置 C	11.50	0.55	0.734
设置 D	18.96	0.74	0.237
设置 E	17.99	0.72	0.242
设置 F	18.14	0.73	0.245
RAIC	19.98	0.76	0.231

为了探究本文所提调整因子根据局部区域自适应变化对最终增强图像的影响, 设计了 3 组消融实验, 其中调整因子的值分别固定为 -0.2 , -0.5 和 -0.8 。结合图 8 和表 5 可知, 当调整因子固定为 -0.2 时, 对图像整体尤其是低亮度区域的提升严重不足, 当固定为 -0.8 时, 图像整体曝光过度, 这两种情况下 PSNR, SSIM 和 LPIPS 指标均大幅下降。当固定为 -0.5 时, 图像的视觉效果有一定改善, 但在评价指标上仍与调整因子能够根据图像局部区域自适应变化时有一定差距。可知当调整因子根据不同区域自适应变化时, 不仅可以达到更加理想的增强效果, 在增强不同低照度图像时还可避免人为指定调整因子大小带来的影响, 提升算法的泛用性。




图 8 调整因子消融实验

Fig. 8 Ablation experiment of adjustment factor

表 5 调整因子消融实验指标对比

Table 5 Comparison of indicators of ablation experiments on adjustment factors

消融实验	PSNR	SSIM	LPIPS
$A_n(x) = -0.2$	11.34	0.55	0.305
$A_n(x) = -0.5$	18.85	0.69	0.259
$A_n(x) = -0.8$	14.94	0.64	0.299
RAIC	19.98	0.76	0.231

结束语 针对现有低照度图像增强算法中基于 Retinex 理论的算法网络结构复杂, 以及基于曲线估计的算法无法同时解决亮度不佳、颜色失真、噪声严重等问题, 本文提出了一种基于 Retinex 理论的低照度图像自适应增强算法。首先,

低照度图像经过投影模块去除不适合的噪声; 其次, 分解网络将图像分解为照度分量和反射分量; 最后, 照度分量经过自适应迭代曲线调整, 与反射分量相乘得到增强图像。实验证明, 本文算法在多个数据集上取得了很好的结果, 在增强图像亮度的同时有效还原了图像的颜色和结构信息, 在客观评价指标上优于当前主流算法。本文的后续工作将聚焦于探索低照度图像增强与目标检测、图像识别和语义分割等高级视觉任务的联系, 进一步优化模型与性能。

参考文献

- [1] WU X Q, ZHOU W J, ZUO C L, et al. Salient object detection method based on multi-scale visual perception feature fusion[J]. Computer Science, 2024, 51(5): 143-150.
- [2] LIU Y T, LI P, SUN Y Y, et al. Image recognition with deep dynamic joint adaptation networks[J]. Computer Science, 2021, 48(6): 131-137.
- [3] ZHANG F C, ZHONG G Q, MAO Y X. Neural architecture search for light-weight medical image segmentation network[J]. Computer Science, 2022, 49(10): 183-190.
- [4] IBRAHIM H, KONG N S P. Brightness preserving dynamic histogram equalization for image contrast enhancement [J]. IEEE Transactions on Consumer Electronics, 2007, 53(4): 1752-1758.
- [5] JOHN J M. Lightness and retinex theory [J]. Journal of the Optical Society of America, 1970, 61(1): 1-11.
- [6] 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.
- [7] WEI C, WANG W, YANG W, et al. Deep retinex decomposition for low-light enhancement [J]. arXiv:1808.04560, 2018.
- [8] ZHANG Y, ZHANG J, GUO X. Kindling the darkness: A practical low-light image enhancer [C]// Proceedings of the 27th ACM International Conference on Multimedia. 2019: 1632-1640.
- [9] ZHANG Y, GUO X, MA J, et al. Beyond brightening low-light images [J]. International Journal of Computer Vision, 2021, 129(4): 1013-1037.
- [10] LIU R, MA L, ZHANG J, et al. Retinex-inspired unrolling with cooperative prior architecture search for low-light image enhancement [C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2021: 10561-10570.
- [11] ZHAO Z, XIONG B, WANG L, et al. RetinexDIP: A Unified Deep Framework for Low-Light Image Enhancement [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2022, 32(3): 1076-1088.
- [12] HAI J, XUAN Z, YANG R, et al. R2RNet: Low-light image enhancement via Real-low to Real-normal Network [J]. Journal of Visual Communication and Image Representation, 2023, 90: 1037-1048.
- [13] ZHANG L, ZHANG L, LIU X, et al. Zero-shot restoration of back-lit images using deep internal learning [C]// Proceedings of the 27th ACM International Conference on Multimedia. 2019: 1623-1631.
- [14] GUO C, LI C, GUO J, et al. Zero-reference deep curve estimation for low-light image enhancement [C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2020: 1780-1789.

- [15] ZHU A, ZHANG L, SHEN Y, et al. Zero-Shot Restoration of Underexposed Images via Robust Retinex Decomposition [C]// Proceedings of the IEEE/CVF International Conference on Multimedia and Expo. 2020:1-6.
- [16] ZHENG S, GUPTA G. Semantic-guided zero-shot learning for lowlight image/video enhancement [C] // Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision. 2022:581-590.
- [17] WEN J, WU C, ZHANG T, et al. Self-Reference Deep Adaptive Curve Estimation for Low-Light Image Enhancement [J]. arXiv:2308.08197, 2023.
- [18] JIANG Y, GONG X, LIU D, et al. Enlightengan: Deep light enhancement without paired supervision [J]. IEEE Transactions on Image Processing, 2021, 30: 2340-2349.
- [19] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation [C]// Proceedings of the Medical Image Computing and Computer-Assisted Intervention. 2015:234-241.
- [20] MA L, MA T, LIU R, et al. Toward fast, flexible, and robust low-light image enhancement [C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2022:5637-5646.
- [21] CUI Z, LI K, GU L, et al. You Only Need 9 0 K Parameters to Adapt Light: a Light Weight Transformer for Image Enhancement and Exposure Correction [J]. arXiv:2205.14871, 2022.
- [22] SHAKIBANIA H, RAOUFI S, KHOTANLOU H. CDAN: Convolutional Dense Attention-guided Network for Low-light Image Enhancement [J]. arXiv:2308.12902, 2023.
- [23] JIANG H, LUO A, LIU X H, et al. LightenDiffusion: Unsupervised Low-Light Image Enhancement with Latent-Retinex Diffusion Models [J]. arXiv:2407.08939, 2024.
- [24] CHOBOLA T, LIU Y, ZHANG H, et al. Fast Context-Based Low-Light Image Enhancement via Neural Implicit Representations [J]. arXiv:2407.12511, 2024.
- [25] CHEN Y, ZHU G, WANG X, et al. FMR-Net: a fast multi-scale residual network for low-light image enhancement [J]. Multimedia Systems, 2024, 30(2): 73.
- [26] SHI Y F, ZHAO B T. Low-light Image Enhancement Algorithm Based on Retinex Theory [J]. Journal of Chongqing Technology and Business University(Natural Science Edition), 2023, 40(6): 61-67.
- [27] FU Z, YANG Y, TU X, et al. Learning a Simple Low-light Image Enhancer from Paired Low-light Instances [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2023:22252-22261.
- [28] LI J, FENG X, HUA Z. Low-Light Image Enhancement via Progressive-Recursive Network [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2021, 31(11): 4227-4240.
- [29] CHOLLET F. Xception: Deep Learning with Depthwise Separable Convolutions [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2017:1800-1807.
- [30] CHARBONNIER P, BLANC-FERAUD L, AUBERT G, et al. Two deterministic half-quadratic regularization algorithms for computed imaging [C]// Proceedings of 1st International Conference on Image Processing. 1994:168-172.
- [31] WANG Z, BOVIK A C, SHEIKH H R, et al. Image quality assessment: from error visibility to structural similarity [J]. IEEE Transactions on Image Processing, 2004, 13(4): 600-612.
- [32] LIU C, WU F, WANG X. EFINet: Restoration for Low-Light Images via Enhancement-Fusion Iterative Network [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2022, 32(12): 8486-8499.
- [33] ZHANG Y, DI X, WU J, et al. Simplifying Low-Light Image Enhancement Networks with Relative Loss Functions [J]. arXiv: 2304.02978, 2023.
- [34] WANG S, ZHENG J, HU H, et al. Naturalness Preserved Enhancement Algorithm for Non-Uniform Illumination Images [J]. IEEE Transactions on Image Processing, 2013, 22(9): 3538-3548.
- [35] CAI J, GU S, ZHANG L. Learning a Deep Single Image Contrast Enhancer from Multi-Exposure Images [J]. IEEE Transactions on Image Processing, 2018, 27(4): 2049-2062.
- [36] 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.
- [37] GUO X, LI Y, LING H. LIME: Low-light image enhancement via illumination map estimation [J]. IEEE Transactions on Image Processing, 2016, 26(2): 982-993.
- [38] MA K, ZENG K, WANG Z. Perceptual quality assessment for multi-exposure image fusion [J]. IEEE Transactions on Image Processing, 2015, 24(11): 3345-3356.
- [39] WANG S, ZHENG J, HU H M, et al. Naturalness preserved enhancement algorithm for non-uniform illumination images [J]. IEEE Transactions on Image Processing, 2013, 22(9): 3538-3548.
- [40] MITTAL A, SOUNDARARAJAN R, BONIKA C. Making a "completely blind" image quality analyzer [J]. IEEE Signal Processing Letters, 2012, 20(3): 209-212.
- [41] HUYNH-THU Q, GHANBARI M. Scope of validity of PSNR in image/video quality assessment [J]. Electronics Letters, 2008, 44(13): 800-801.
- [42] ZHANG R, ISOLA P, EFROS A, et al. The Unreasonable Effectiveness of Deep Features as a Perceptual Metric [J]. arXiv: 1801.03924, 2018.



ZHENG Dichen, born in 2000, post-graduate. His main research interests include image processing and computer vision.



ZHANG Dengyin, born in 1964, Ph.D., researcher, Ph.D supervisor. His main research interests include signal and information processing and information security.