

DOI: 10.13382/j.jemi.B2408045

结合 Retinex 与扩散模型的低照度图像增强方法^{*}

邹伊雯^{1,2} 卢 笑^{1,2} 汪鲁才^{1,2} 吴成中³ 王耀南³

(1. 湖南师范大学工程与设计学院 长沙 410081; 2. 智能传感与康复机器人湖南省高校重点实验室 长沙 410081;

3. 机器人视觉感知与控制技术国家工程研究中心 长沙 410082)

摘 要:针对现有基于 Retinex 理论的低照度图像增强方法存在的缺陷,如训练方式复杂、训练过程中光照分量和反射分量真值的获取难题,以及对于光照条件极差情况下的图像增强,往往还伴随着放大暗处噪声以及丢失图像结构细节等影响图像质量的问题。本文提出了端到端的两阶段图像增强网络,结合 Retinex 理论与扩散模型对低照度图像进行增强。第1阶段根据 Retinex 理论,重点关注提升低照度图像亮度,提出采用卷积神经网络估计三通道光照比图,与低照度图像点积得到初步的增强处理的结果;单纯的 Retinex 方法基本没有考虑到在点亮图像过程中藏匿于暗处的退化,将低照度图像初步提亮后,第2阶段侧重于利用扩散模型优秀的去噪能力对图像进行去噪修复,提出亮度感知扩散模型,将 HSI 颜色空间的亮度图作为条件,充分利用扩散模型的优势来修复初步增强过程中的退化,并由颜色校正模块来减轻扩散模型逆过程中可能出现的全局劣化,得到增强后的图像。实验结果表明,在低照度数据集上与近年来其他 10 种优秀的算法相比较,训练测试得到的结果在峰值信噪比与图像感知相似度指标分别为 27.517 和 0.087,均优于进行实验的其他方法,结构相似性为 0.874,取得次优值。提出的方法能很好地适应未知噪声和光照的分布,在提升图像亮度、去除图像噪声以及防止图像细节模糊等方面取得了较好的效果,能够得到更自然以及更高质量的图像增强效果。

关键词: 图像增强;低照度;Retinex;扩散模型;颜色校正

中图分类号: TP391.41; TN01 文献标识码: A 国家标准学科分类代码: 510.40

Low-light image enhancement based on Retinex theory and diffusion model

Zou Yiwen^{1,2} Lu Xiao^{1,2} Wang Lucai^{1,2} Wu Chengzhong³ Wang Yaonan³

(1. School of Engineering and Design, Hunan Normal University, Changsha 410081, China; 2. The Key Laboratory of Intelligent Sensing and Rehabilitation Robotics of Hunan Province Universities, Changsha 410081, China;

3. National Engineering Research Center of Robot Visual Perception and Control Technology, Changsha 410082, China)

Abstract: To address the flaws of existing low-light image enhancement methods based on Retinex theory, such as complex training procedures, difficulties in acquiring the ground truths of illumination and reflection components during training, and issues affecting image quality by amplifying dark-region noise and losing structural details when enhancing images under extremely poor lighting conditions, this paper proposes an end-to-end two-stage image enhancement network that combines Retinex theory with diffusion models. In the first stage, guided by Retinex theory, the focus is on improving the brightness of low-light images. A convolutional neural network (CNN) is adopted to estimate the three-channel illumination ratio map, which is then dot-multiplied with the low-light image to obtain the initial enhanced result. Pure Retinex methods barely consider the degradations hidden in dark areas during brightness enhancement. After initially brightening the low-light image, the second stage focuses on denoising and restoring the image using the excellent denoising capability of diffusion models. A brightness-aware diffusion model is proposed, which takes the luminance map in the HSI color space as a condition to fully leverage the advantages of diffusion models in repairing degradations from the initial enhancement. A color correction module is also introduced to mitigate potential global degradation during the inverse process of the diffusion model, yielding the final enhanced image. Experimental results show that compared with 10 other state-of-the-art algorithms on low-light datasets, the proposed

收稿日期: 2024-12-16 Received Date: 2024-12-16

^{*} 基金项目: 国家自然科学基金(62007007, 62277004)、湖南省学位与研究生教学改革研究重点项目(2022JGZD026)、湖南省自然科学基金(2023JJ30415, 2022JJ30395)、湖南省自然科学基金(2025JJ50362)、湖南省教育厅优秀青年项目(24B0081)资助

method achieves a peak signal-to-noise ratio (PSNR) of 27.517 and a structural similarity index (SSIM) of 0.874 (a near-optimal value), along with an image perception similarity of 0.087-all outperforming the compared methods. The proposed method can well adapt to the distributions of unknown noise and illumination, achieving excellent performance in brightness enhancement, noise removal, and detail preservation, and generating more natural and high-quality enhanced images.

Keywords: image enhancement; low-light images; Retinex; diffusion model; color corrector

0 引言

图像,作为计算机视觉领域不可或缺的信息载体,承担着准确传达信息的重任。然而在许多低光照的场景中进行拍摄时,往往难以得到高质量的图像,视觉效果也大打折扣。低照度图像给人的视觉感知带来了挑战,同时也阻碍着如目标检测、医学图像分割等一系列下游计算机视觉任务发展。

现有传统的低照度图像增强方法在大体上可以分为直方图均衡化 (histogram equalization HE)^[1] 和基于 Retinex 理论^[2] 的方法两大类。直方图均衡化根据图像灰度值概率密度分布计算得到累计直方图,然后进行区间转换,得到具有均匀灰度概率密度分布的图像。Retinex 理论由来已久,该理论于 20 世纪 70 年代前后提出,模拟人类视觉系统,此后大量对于 Retinex 理论的研究不断发展,到现今 Retinex 理论主要应用于数字图像的增强,使图像更接近人眼视觉效果。基于原始的 Retinex 理论,研究人员将其改进后提出了多尺度 Retinex 算法 (multi scale retinex, MSR),对不同尺度的 Retinex 输出进行加权求和,最后进行修正来修复颜色失真,在多尺度 Retinex 算法的基础之上,多尺度 Retinex 彩色恢复算法 (multi scale Retinex with color restoration, MSRRCR),采用多尺度 Retinex 增强的同时保持图像细节,使用对数颜色恢复因子校正图像颜色,一定程度保持图像的颜色恒常性^[3]。

传统的 Retinex 方法容易引入严重的噪声并且扭曲图像的颜色,导致增强的图像不符合真实曝光条件下的图像场景。

深度学习近年来迅速发展,卷积神经网络 (convolutional neural network, CNN)^[4] 也在低照度图像增强中得到了广泛的应用。深度学习在低照度图像增强等图像增强的问题中的表现相较于传统的方法有更为出色的表现,逐渐成为主流。

Fu 等^[5] 提出了基于生成对抗网络的无监督低光图像增强网络 LE-GAN,其中设计了光照感知注意力模块,空间照明注意力和全局照明注意力两个分支更好地利用图像上下文及全局信息,提升增强图像的视觉质量。Guo 等^[6] 提出将低照度图像增强任务以深度学习估计图像特定曲线的方式进行,提高了图像增强的质量以及网络的

计算效率和泛化能力。

由于通过数据驱动的深度学习方法忽略了图像增强过程中反射分量与照度分量的数学建模以及人类视觉上的颜色感知。因此也有研究者提出了结合 Retinex 与深度学习的低照度图像增强方法。

结合 Retinex 的深度学习方法,Guo 等^[7] 提出的低照度图像增强方法 LIME 仅对光照图进行优化,其优化过程首先计算 R、G、B 通道中的最大值作为初始光照图,再利用结构先验优化光照图。Wei 等^[8] 提出用于低照度图像增强的 Retinex 深度神经网络 Retinex-Net,模型包含分解网络和光照调整网络,实现了更有效更高质量的低照度图像增强。Zhang 等^[9] 提出的 KinD++ 模型将图像分解为光照图和反射图分别及进行优化,灵活调整光照强度,得到更自然,细节更丰富的图像。Ma 等^[10] 自校准光照学习框架 SCI,通过级联的方式学习光照,各阶段共享权重以及通过自校准的方式对光照进行优化,收敛每个阶段实验结果,提升了图像的视觉质量以及网络计算效率。Cai 等^[11] 提出 Retinexformer 框架首先估计光照初步提升图像亮度,并设计了光照引导的自注意力机制修复初步提亮图像过程中产生的噪声、细节模糊等退化。但是同时处理两个分量容易导致图像细节的丢失,训练过程也较为繁琐,更重要的是在监督学习中光照图和反射图真值的获取本身也是一个难题。

扩散模型自提出以来,在图像生成领域取得了优异的表现,扩散模型也陆续用于低照度图像增强。

Jiang 等^[12] 提出了基于小波的扩散模型 (DiffLL),将图像小波域低频分量通过扩散模型进行增强,设计高频恢复模块利用图像水平和垂直细节补充结构信息。Yi 等^[13] 设计基于 Transformer 的网络分解图像为光照图与反射图,通过双路径的扩散模型重建正常光照图以及修复退化的反射图,使增强的图像细节更清晰,扩散模型带来了更好的泛化性能。Zhou 等^[14] 提出金字塔扩散的方法,通过逐步提高分辨率来使扩散模型拥有更快的速度,并采用全局校正模块减轻逆采样过程的退化。而这些方法并没有很好利用到扩散模型的去噪的优势,并且训练方式复杂,需要分模块分布训练再进行微调。

综上所述,传统的 HE 和基于 Retinex 的方法容易放大噪声,造成细节模糊,而现有的基于 Retinex 的深度学习方法由于光照图和反射图的真值图像难以获取,从而导致网络训练困难,并且容易产生色偏、伪影等问题。

基于以上问题,本文结合 Retinex 理论与扩散模型进行低照度图像增强,通过端到端的训练提升图像生成的质量。首先,针对现有方法通过深度学习训练神经网络直接估计光照图和反射图难以得到真值图像的问题,提出利用正常光与低光照图像的比值训练光照比估计网络,实现低光照图像的初步亮度提升,从而避免了两个分量真值的获取。其次,为了改善初步点亮图像的噪声退化、细节模糊等问题,提出亮度感知扩散模型,进行图像去噪修复,得到细节清晰的高质量图像,同时引入颜色校正(color corrector, CC)模块^[14]缓解扩散过程逆采样造成的色偏。

本文提出了 ReLight-Diff 框架,一种二阶段端到端的低照度图像增强方法,第 1 阶段提升图像亮度,第 2 阶段采用亮度感知扩散模型修复第 1 阶段产生的噪声退化以及细节模糊的问题。根据 Retinex 理论公式,训练网络估计三通道光照比图像,避免了光照图和反射图真值难以获取的问题,同时三通道图与低照度图像进行点积的过程中提高了增强时 RGB 三通道非线性程度。本文提出

的方法在低照度数据集(low-light dataset, LOL)^[7]上进行实验,实验结果得到峰值信噪比(peak signal-to-noise ratio, PSNR)、结构相似性(structural similarity index measure, SSIM)和图像感知相似度(learned perceptual image patch similarity, LPIPS)指标均得到优化。

1 本文方法

针对现有基于 Retinex 理论的低照度图像增强方法存在的缺陷,提出了端到端的两阶段图像增强网络,结合 Retinex 理论与扩散模型对低照度图像进行增强。

1.1 整体框架

针对现有基于 Retinex 理论的深度学习方法存在的训练方式复杂,细节丢失,色偏等问题,本文提出结合 Retinex 理论与扩散模型的低照度图像增强方法(ReLight-Diff),该方法整体框架如图 1 所示,包括光照比估计网络(L-RNet)以及亮度感知扩散模型(I-DM)两个部分。

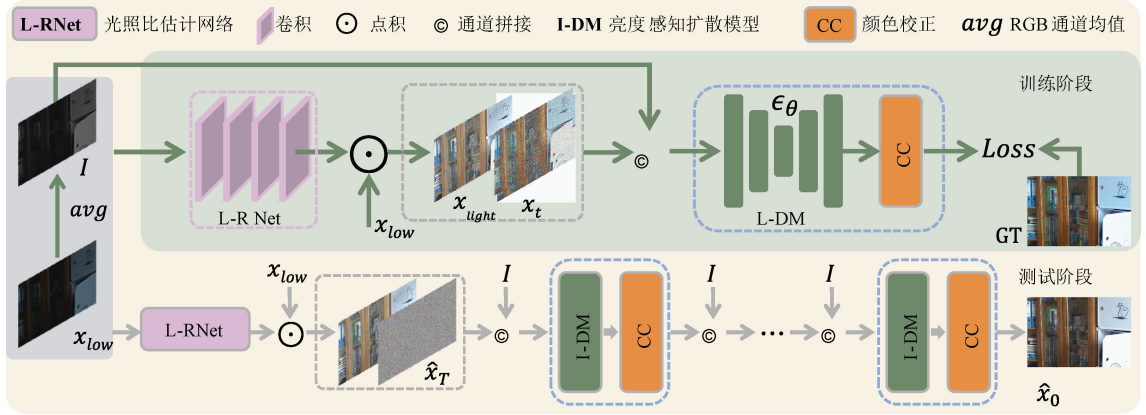


图 1 ReLight-Diff 总框架结构

Fig. 1 Network architecture of ReLight-Diff

给定低照度图像 x_{low} , 首先计算其 RGB 均值得到 HSI 颜色空间的亮度分量 I , 然后与低照度图像进行通道拼接后输入光照比估计网络。将正常光照与低光照图像的比值作为网络训练过程的真值, 在无需光照图和反射图真值的条件下实现低光照图像的亮度提升。其次将光照比估计网络的输出与输入图像进行点积, 得到初步亮度提升的结果图像 x_{light} 。由于低照度图像本身存在退化和噪声等, 导致初步增强结果会出现噪声放大、细节模糊等退化现象。因此, 本文将初步增强的图像 x_{light} 与亮度分量 I 作为扩散模型的条件输入, 训练亮度感知扩散模型, 并生成细节清晰的去噪图像。为了减轻逆过程的颜色偏移, 在扩散模型训练过程中接入 CC 模块。

1.2 光照比估计网络

原始的 Retinex 理论认为一幅彩色图像可以分解为

光照图和反射图, 光照图反映了图像受光照的影响, 而反射图则是图像固有颜色的反映, 其分解公式如下:

$$x = R \cdot L \quad (1)$$

式中: x 、 R 和 L 分别表示输入彩色图像、反射图和光照图。反射图包含了图像场景信息, 在不同光照条件下保持一致, 光照图表示图像中场景在不同光照下的不同状态。

根据 Retinex 理论基于颜色恒常性理论, 理论上不同光照条件下图像的反射图相同, 正常光状态下的图像与低照度图像之比(简称光照比) $L_r \in \mathbf{R}^{H \times W \times 3}$, L_r 即正常光图像与低照度图像之比, 公式如下:

$$\frac{x_{high}}{x_{low}} = \frac{L_H \cdot R_H}{L_L \cdot R_L} \quad (2)$$

式中: $x_{high} \in \mathbf{R}^{H \times W \times 3}$ 和 $x_{low} \in \mathbf{R}^{H \times W \times 3}$ 分别表示正常光和低

照度图像; R_H 和 L_H 分别表示正常光图像的反射图和光照图; R_L 和 L_L 分别表示低照度图像的反射图和光照图。

根据以上理论推理过程,设计采用神经网络估计低照度图像增强至正常光图像所需光照比,将低照度图像 x_{low} 以及低照度图像在 HSI 颜色空间的亮度分量 $I \in \mathbf{R}^{H \times W \times 3}$ 作为输入,亮度分量计算公式如下:

$$I = \frac{R(x_{low}) + G(x_{low}) + B(x_{low})}{3} \quad (3)$$

由于 x_{high} 和 x_{low} 已知,通过二者的比值训练网络 $\varepsilon(\cdot)$ 估计光照比,这样可以避免两个分量真值的获取。




图2 光照比估计网络

Fig. 2 The network of estimating illumination-rate image

低照度图像理论上拥有与正常光图像一致的反射图,由于光照条件不好的情况下图像的成像设备会不可避免地引入噪声和伪影等。可视化结果如图3所示,图3(a)是低照度输入图像,图3(b)是网络估计得到的光照比图像,图3(c)是由光照比图得到的初步增强图像。由

因此,本文设计光照比估计网络,该网络由4个简单的卷积层以及激活函数组成,网络训练损失 $Loss_{ir}$ 表示如下:

$$Loss_{ir} = \left\| \frac{x_{high}}{x_{low}} - \varepsilon(x_{low}, I) \right\|_1 \quad (4)$$

为了提高光照图的非线性,获得更好的点亮效果,网络估计输出三通道光照比图,图2所示为由光照比估计网络得到的光照比图 L_r 的过程。由此得到仅点亮的初步结果图 x_{light} 为:

$$x_{light} = x_{low} \cdot L_r \quad (5)$$

图3可以看出,得到光照比图时暗区图像噪声也会被分解为光照比图的一部分,容易导致图像增强过程中较严重的噪声干扰。扩散模型在图像生成时出色的去噪和生成能力,采用扩散模型重建图像,能充分发挥扩散模型的去噪生成能力。



图3 初步增强过程的图像可视化结果

Fig. 3 Visualization results of the initial enhancement process

1.3 亮度感知扩散模型

亮度图像中的亮度以及结构信息对于低照度图像增强过程中的去噪修复非常重要。本文的亮度感知扩散模型输入初步增强的图像以及 HSI 颜色空间的亮度分量 I 作

为扩散模型的条件输入,亮度信息能更好地为扩散模型的去噪生成过程提供亮度以及结构信息,使扩散修复的图像更加自然,细节更清晰。

初始的扩散模型 (denoising diffusion probabilistic

models, DDPM)^[15]将图像生成描述为正向加噪过程与逆向去噪过程两个步骤。正向过程中,给定需要生成的正常光图像 x_0 样本分布 $x_0 \sim p(x_0)$, 通过 T 步的马尔可夫链逐步添加高斯噪声,使样本图像最终呈现为一幅遵循高斯分布的纯噪声图。加噪过程如下:

$$q(x_t | x_{t-1}) = \mathcal{N}(x_t; \sqrt{\alpha_t} x_{t-1}, (1 - \alpha_t)I) \quad (6)$$

式中: x_t 与 x_{t-1} 分别是时间步为 t 和 $t-1$ 对 x_0 加噪的图像; $\alpha_t = 1 - \beta_t$, $\beta_t \in (0, 1)$, 并且 $\alpha_{t-1} \geq \alpha_t$, $\bar{\alpha}_t = \prod_{i=1}^t \alpha_i$ 。根据公式推理,样本图像添加噪声 ϵ 得到纯噪声图像的过程简化为:

$$x_t = \sqrt{\bar{\alpha}_t} x_0 + \sqrt{1 - \bar{\alpha}_t} \epsilon \quad (7)$$

逆向去噪过程是逆转正向过程中的加噪过程,学习将纯噪声图像样本还原为原始清晰图像样本。在训练过程中,真值图像正向过程添加噪声,逆向过程通过网络估计正向过程添加至图像的噪声。从噪声样本 x_T 开始逐步去噪,但由于真实后验分布 $p(\hat{x}_{t-1} | \hat{x}_t)$ 难以直接计算,通过变分推断计算得到近似概率分布 $q(\hat{x}_{t-1} | \hat{x}_t, \hat{x}_0)$ 是可行的,至此逆向去噪过程转化为网络可学习的过程。由当前状态下近似分布表达式如下:

$$q(\hat{x}_{t-1} | \hat{x}_t, \hat{x}_0) = \mathcal{N}(\hat{x}_{t-1}; \tilde{\mu}_t(\hat{x}_t, \hat{x}_0), \tilde{\beta}_t I) \quad (8)$$

式中: $\tilde{\beta}_t$ 为方差项通常为固定值或简单的时间相关函数; $\tilde{\mu}_t(\cdot)$ 为均值,取决于当前 \hat{x}_t 和 \hat{x}_0 ; 而 $\hat{x}_t, \hat{x}_{t-1}, \hat{x}_0$ 分别表示第 $t, t-1$ 以及逆向过程中由式(7)推理得到的近似正常光图。 \hat{x}_0 的计算过程如下:

$$\hat{x}_0 = \frac{1}{\sqrt{\bar{\alpha}_t}} \hat{x}_t + \sqrt{1 - \bar{\alpha}_t} \epsilon_\theta(\hat{x}_t, x_{light}, I, t) \quad (9)$$

为了在不影响图像生成质量的情况下减少生成图像采样的步数,加速图像的生成速度,本文方法采用对 DDPM 逆向采样生成过程改进后的降噪扩散隐式模型(denoising diffusion implicit models, DDIM)^[16],该方法将通过构造新的分布,得到一个跳出马尔可夫链的采样过程。重新建模并得到逆向采样过程表达式如下:

$$q(\hat{x}_{t-1} | \hat{x}_t, \hat{x}_0) = \mathcal{N}(\hat{x}_{t-1}; k_t \hat{x}_t + \lambda_t \hat{x}_0, \sigma_t^2 I) \quad (10)$$

$$\hat{x}_{t-1} = k_t \hat{x}_t + \lambda_t \hat{x}_0 + \sigma_t \epsilon_\theta(\hat{x}_t, x_{light}, I, t) \quad (11)$$

式中: $\epsilon_\theta(\hat{x}_t, x_{light}, I, t)$ 表示由网络估计加噪过程在第 t 步的噪声,后写作 ϵ_θ 。整个逆向去噪过程将转变为深度学习网络拟合均值计算过程中所需噪声 ϵ 的过程,与 DDPM 中的逆过程分布保持一致,由生成 \hat{x}_{t-1} 的逆采样公式中逆向推导可以分别得到 k_t 和 λ_t , 其方差 σ_t 参数通常由人工定义为:

$$k_t = \frac{\sqrt{1 - \bar{\alpha}_t - \sigma_t^2}}{\sqrt{1 - \bar{\alpha}_t}} \quad (12)$$

$$\lambda_t = \sqrt{\bar{\alpha}_{t-1}} - \frac{\sqrt{\bar{\alpha}_t} \cdot \sqrt{1 - \bar{\alpha}_t - \sigma_t^2}}{\sqrt{1 - \bar{\alpha}_t}} \quad (13)$$

$$\sigma_t^2 = \eta \cdot \frac{(1 - \alpha_t)(1 - \bar{\alpha}_{t-1})}{1 - \bar{\alpha}_t} \quad (14)$$

当 $\eta = 1$ 时,逆向采样过程基本与 DDPM 相同;而当 $\eta = 0$ 时,采样过程中没有引入随机噪声,生成图像的过程是一个更具确定性的过程,即 DDIM。当前状态下 \hat{x}_t 的分布已知, $\eta = 0$, 将 k_t 和 λ_t 代入式(11)中得到:

$$\hat{x}_{t-1} = \sqrt{\bar{\alpha}_{t-1}} \left(\frac{\hat{x}_t - \sqrt{1 - \bar{\alpha}_t} \epsilon_\theta}{\sqrt{\bar{\alpha}_t}} \right) + \sqrt{1 - \bar{\alpha}_{t-1}} \epsilon_\theta \quad (15)$$

DDIM 采用确定性的采样过程,减少了生成的随机性,即模型在相同的初始条件下会得到相同的输出,其最终的采样过程如式(15)所示。扩散模型训练的损失函数如下:

$$Loss_{diff} = \|\epsilon - \epsilon_\theta\|_1 \quad (16)$$

1.4 颜色校正模块

在扩散模型进行逆向图像生成过程中,采用 CC 模块在不影响图像生成质量的同时减轻扩散模型忽视的 RGB 颜色偏移。扩散模型估计的噪声 ϵ_θ 与实际需要的噪声 ϵ 存在微小的误差,而当时间步 t 较大的时候, ϵ 前面的系数也相应的较大,放大了误差,导致 RGB 偏移的现象,采用颜色校正模块对逆向扩散过程产生的 RGB 偏移进行修复。

颜色校正模块如图 4 所示,模块中计算输入噪声嵌入,计算输入图像的条件特征并生成对应的缩放和偏移参数,并将输入图像经过卷积操作后进行相应的仿射变换和缩放平移操作。进行 3 次以上操作后,最终返回校正后的输出。损失计算过程如下:

$$Loss_{cc} = \|\hat{x}_0 - x_0\|_1 \quad (17)$$

训练过程中,损失函数均采用 $L1$ 损失,最终网络训练过程中的总损失函数如下:

$$Loss = Loss_{diff} + Loss_{cc} + Loss_{ir} \quad (18)$$

完整的模型训练过程如算法 1 所示,在亮度提升阶段,输入低照度图像 x_{low} , 并计算得到亮度分量,通道拼接后一同输入光照比估计模块,得到光照比图与低照度图像进行点积得到初步的增强图像 x_{light} 。在退化修复阶段,图像 x_{light} 与亮度分量 I 作为扩散模型的条件,并随机采样得到时间步 t , 通过前向过程的加噪公式,得到由正常光图像经过 t 指时间步加噪后的图像 x_t , 由 Unet 网络估计前向过程中添加的噪声,并得到去噪后的结果图像。计算逆向过程的系数,当大于阈值时,通过颜色校正模块得到增强的图像,本文实验阈值设置为 $\gamma = 1$ 。

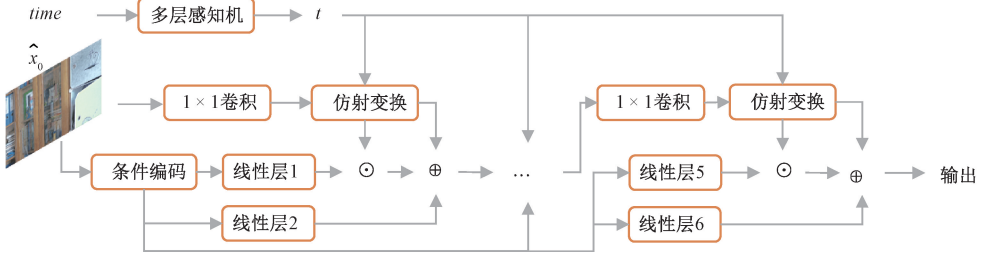


图4 颜色校模块结构

Fig.4 The structure of color corrector module

算法1. 训练过程

```

1: 输入: 低照度/正常光图像对  $(x_{low}, x_0)$ , 噪声时刻表  $\alpha$ , 校正阈值  $\gamma$ .
2: 重复
3:   采样图像对  $(x_{low}, x_0)$ 
4:   采样  $t \sim \text{Uniform}(1, \dots, T)$ 
5:   采样  $\epsilon \sim \mathcal{N}(0, 1)$ 
6:    $I = \frac{R(x_{low}) + G(x_{low}) + B(x_{low})}{3}$ 
7:    $x_{light} = x_{low} \cdot \mathcal{E}(x_{low}, I)$ 
8:    $x_t = \sqrt{\alpha_t} x_0 + \sqrt{1 - \alpha_t} \epsilon$ 
9:   采用梯度下降法
       $\nabla_{\theta} \{ \epsilon - \epsilon_{\theta}(x_t, x_{light}, I, t)_1 + \text{Loss}_{ir} \}$ 
10:  if  $\frac{\sqrt{1 - \alpha_t}}{\sqrt{\alpha_t}} > \gamma$  then
11:    梯度下降法
       $\nabla_{\theta} \| \eta(\hat{x}_0) - x_0 \|_1$ 
12:  end if
13: 直至收敛

```

算法2 测试过程

```

1: 输入: 低照度图像  $x_{low}$ , 噪声时刻表  $\alpha$ , 校正阈值  $\gamma$ , 隐式采样间隔  $S$ 
2: 采样  $\hat{x}_T \sim \mathcal{N}(0, 1)$ 
3:  $I = \frac{R(x_{low}) + G(x_{low}) + B(x_{low})}{3}$ 
4:  $x_{light} = x_{low} \cdot \mathcal{E}(x_{low}, I)$ 
5: for  $i = T/S: 0$ 
6:   $\hat{x}_{i-1} \leftarrow \sqrt{\alpha_{i-1}} \left( \frac{\hat{x}_i - \sqrt{1 - \alpha_i} \epsilon_{\theta}}{\sqrt{\alpha_i}} \right) + \sqrt{1 - \alpha_{i-1}} \epsilon_{\theta}$ 
7:  if  $\frac{\sqrt{1 - \alpha_i}}{\sqrt{\alpha_i}} > \gamma$  then
8:     $\hat{x}_0 \leftarrow \eta(\hat{x}_0)$ 
9:  end if
10: end for
11: 返回  $\hat{x}_0$ 

```

测试过程的算法2所示。计算低照度图 HSI 颜色空间的亮度分量 I 低照度图像作为输入, 经由光照比图估计网络得到光照比图, 计算得到初步增强结果, 再将其作为扩散模型的条件输入进行退化修复。由网络估计得到噪声 ϵ_{θ} , 并进行由逆向采样计算得到增强的图像。同时, 当系数计算大于阈值 γ 时使用颜色校正网络对生成过程进行颜色校正, 以减轻图像的颜色偏移。

2 实验结果与分析

2.1 实验设置

1) 数据集

本文方法在 LOLv1 数据集上进行训练和评估, 其中包含训练集 485 对配对的低照度与正常光图像以及 15 对配对的测试集图像, 分辨率为 400×600 , 均为真实场景中不同曝光条件下拍摄的图像。在进行比较的方法中, 采用其在 LOL 数据集上预训练的模型参数。

2) 模型训练设置

扩散模型借鉴了 Saharia 等^[17]提出的超分辨率网络

SR3 中条件扩散模型的思想, 使用 PyTorch 框架实现, 在搭载两块 NVIDIA RTX2080Ti GPU 的计算机上进行训练。实验过程中, batch size 设置为 12, patch size 设置为 160×160 , 训练过程共迭代 100 万次, 使用 Adam 优化器对网络参数进行优化, 初始学习率设置为 3×10^{-5} 。扩散模型时间步 T 取值 1 000, 训练过程中 β 由 0.000 1 线性增加到 0.02, 损失函数均采用 $L1$ 损失。逆过程采用 DDIM 采样方式, 逆向采样迭代得到生成结果。本文所提模型计算量为 646.60 GFLOPs, 参数量为 55.48×10^6 。

3) 评价指标

对于模型增强低照度图像质量的评估, 采用了 PSNR 测量增强图像与真值图像之间的平均像素相似性, SSIM 对图像结构相似性进行测量, LPIPS 测量图像对的感知差异。

2.2 实验结果

将本文的方法与多种先进的方法进行比较, 表1为不同低照度图像增强方法的定量结果指标对比, 可以看到 PSNR 与 LPIPS 两个指标均优于其他方法。图5所示为 LOLv1 数据集上评估的可视化结果, 并且对一些细节部分及进行了放大, 便于视觉评估。如图5(b)和(c)所

示, EnlightenGAN 和 Zero-DCE 在亮度提升的方面比较差, 而且没有很好地处理暗区的噪声, 导致增强结果仍然较为昏暗模糊。由图 5(d) 和(e) 可知, SNR-Aware 和 URetinex-Net 虽然有更好的亮度提升效果但边缘模糊, 同时与真值图像对比能够看出比较明显的颜色偏差。由图

5(f) 和(h) 可知, LLFlow 和 PyDiff 方法的增强结果在阴影区域的结构纹理模糊, 并且也存在较为明显的颜色偏移现象。由图 5(g) 可知, Retinexformer 方法同样有颜色偏移现象并且噪声的存在模糊了图像细节。




图 5 LOL 数据集上不同算法进行低照度图像增强的可视化结果对比

Fig. 5 Comparison of visualization results of different algorithms for low-light image enhancement on LOL dataset

与许多近年来优秀低照度图像相比, 由表 1 可以看出, 本文所提出的方法增强图像在指标上获得了较好的表现。所有方法都没有在 3 个指标上均优于其他方法, 而且可以看到所提出的方法同时在 PSNR 与 LPIPS 两个指标优于其他方法。实验结果对比表明本文的方法能够达到更为自然效果, 并且更好地保留了图像的细节特征。

2.3 消融实验

本文在有无颜色校正模块和亮度图条件的情况下进行了消融实验, 以研究网络中颜色校正模块以及亮度图条件对图像增强结果的影响, 表 2 是实验结果的定量分析, 可以看出颜色校正模块和亮度分量对 PSNR、SSIM 以及 LPIPS 三个定量指标均有一定提升作用。

表 1 不同模型在 LOLv1 数据集结果的定量比较

Table 1 Quantitative comparisons of different methods on LOLv1

模型	PSNR ↑	SSIM ↑	LPIPS ↓
Zero-DCE ^[6]	14. 861	0. 562	0. 335
LIME ^[7]	16. 760	0. 560	0. 350
RetinexNet ^[8]	16. 770	0. 462	0. 474
EnlightenGAN ^[18]	17. 483	0. 652	0. 335
KinD ^[19]	20. 870	0. 799	0. 207
KinD++ ^[9]	21. 300	0. 820	0. 175
URetinex-Net ^[20]	21. 592	0. 718	0. 290
LLFlow ^[21]	25. 132	0. 872	0. 117
LLFormer ^[22]	25. 758	0. 823	0. 167
DiffLL ^[12]	26. 336	0. 845	0. 217
SNR-Aware ^[23]	26. 811	0. 853	0. 147
PyDiff ^[14]	27. 090	0. 930	0. 100
Retinexformer ^[11]	27. 168	0. 850	0. 125
ReLight-Diff(本文)	27. 517	0. 874	0. 087

表 2 在 LOLv1 数据集上的消融实验
Table 2 Ablation experimental result

模块	PSNR \uparrow	SSIM \uparrow	LPIPS \downarrow
w/o HSI 亮度图	26.203	0.853	0.103
w/o 颜色校正	26.964	0.867	0.096
Relight-Diff(本文)	27.517	0.874	0.087

图 6 所示为消融实验的可视化结果对比,从人类视觉的主观观察来看,可以发现无亮度图作为条件产生的结果会产生明显的伪影、色差以及图像结构模糊等现象。而没有颜色校正模块的增强结果会导致颜色不够鲜艳,色偏的现象依旧存在。




图 6 LOL 数据集上有无颜色校正的可视化结果对比

Fig. 6 Comparison of visualization results with and without color correction on the LOL dataset

3 结 论

本文围绕低照度图像增强方法的讨论,针对许多低照度图像增强方法不能保证图像亮度和质量的同时提升的关键问题,提出了 Retinex 理论应用于图像增强的深度学习方 法。采用了三通道光照比图的概念,提出了端到端的两阶段图像增强网络,在第 1 阶段重点关注了低照度图像的亮度提升,获得将低照度图像初步提亮的结果,在第 2 阶段侧重于利用扩散模型优秀的去噪能力对图像进行去噪修复。利用 Retinex 理论,采用卷积神经网络估计三通道光照比图,摆脱了获取 Retinex 分解需要光照图和反射图真值的不适用问题。扩散模型的采用保证了增强图像的质量,将 HSI 颜色空间的亮度图作为条件,使网络能够更加关注图像结构细节,同时在扩散过程中进行颜色校正来修复增强过程中容易出现的 RGB 偏移,使两阶段增强网络在提升图像亮度的同时保障了图像的清晰度以及优化了细节呈现。未来可进一步探索如何不受限于低照度与正常照度配对数据集,以及减小网络结构的复杂程度两个方面,摆脱配对数据的限制,并且使低照度图像增强网络更适合在资源受限的边缘设备或实时系统中部署。

参考文献

[1] 郭永坤,朱彦陈,刘莉萍,等. 空频域图像增强方法研究综述[J]. 计算机工程与应用,2022,58(11):23-32.
GUO Y K, ZHU Y CH, LIU L P, et al. A review of research on image enhancement methods in the air-frequency domain [J]. Computer Engineering and Application, 2022, 58(11):23-32.

[2] 卢玮,高涛,王翠翠,等. Retinex 理论下基于融合思想的低照度彩色图像增强算法[J]. 科学技术与工程, 2019,19(13): 151-157.
LU W, GAO T, WANG C C, et al. Low illumination color image enhancement algorithm based on fusion idea under Retinex theory [J]. Science Technology and Engineering,2019,19(13): 151-157.

[3] 彭大鑫,甄彤,李智慧. 低光照图像增强研究方法综述[J]. 计算机工程与应用,2023,59(18):14-27.
PENG D X, ZHEN T, LI ZH H. Survey of research methods for low light image enhancement[J]. Computer Engineering and Applications, 2023, 59(18): 14-27.

[4] 汪鲁才,陈春江,邹伊雯,等. 长尾分布下的微藻显微图像轻量级目标检测[J]. 电子测量与仪器学报, 2024,38(4):46-54.
WANG L C, CHEN CH J, ZOU Y W, et al. Lightweight target detection for micro-algae microscopic images under

- long-tailed distribution [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(4): 46-54.
- [5] FU Y, HONG Y, CHEN L, et al. LE-GAN: Unsupervised low-light image enhancement network using attention module and identity invariant loss [J]. Knowledge-Based Systems, 2022, 240: 108010.
- [6] 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.
- [7] 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.
- [8] WEI C, WANG W, YANG W, et al. Deep Retinex decomposition for low-light enhancement [J]. ArXiv preprint arXiv 1808.04560, 2018.
- [9] ZHANG Y, GUO X, MA J, et al. Beyond brightening low-light images[J]. International Journal of Computer Vision, 2021, 129: 1013-1037.
- [10] 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.
- [11] CAI Y, BIAN H, LIN J, et al. Retinexformer: One-stage retinex-based transformer for low-light image enhancement [C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2023: 12504-12513.
- [12] JIANG H, LUO A, FAN H, et al. Low-light image enhancement with wavelet-based diffusion models [J]. ACM Transactions on Graphics (TOG), 2023, 42(6): 1-14.
- [13] YI X, XU H, ZHANG H, et al. Diff-retinex: Rethinking low-light image enhancement with a generative diffusion model[C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2023: 12302-12311.
- [14] ZHOU D, YANG Z, YANG Y. Pyramid diffusion models for low-light image enhancement [J]. ArXiv preprint arXiv 2305.10028, 2023.
- [15] HO J, JAIN A, ABBEEL P. Denoising diffusion probabilistic models[J]. Advances in Neural Information Processing Systems, 2020, 33: 6840-6851.
- [16] SONG J, MENG C, ERMON S. Denoising diffusion implicit models [J]. ArXiv preprint arXiv 2010.02502, 2020.
- [17] SAHARIA C, HO J, CHAN W, et al. Image super-resolution via iterative refinement[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 45(4): 4713-4726.
- [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] 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.
- [20] WU W, WENG J, ZHANG P, et al. Uretinex-net: Retinex-based deep unfolding network for low-light image enhancement [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 5901-5910.
- [21] WANG Y, WAN R, YANG W, et al. Low-light image enhancement with normalizing flow[C]. Proceedings of the AAAI Conference on Artificial Intelligence, 2022, 36(3): 2604-2612.
- [22] WANG T, ZHANG K, SHEN T, et al. Ultra-high-definition low-light image enhancement: A benchmark and transformer-based method [C]. Proceedings of the AAAI Conference on Artificial Intelligence, 2023, 37(3): 2654-2662.
- [23] XU X, WANG R, FU C W, et al. Snr-aware low-light image enhancement [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 17714-17724.


作者简介



邹伊雯, 2022 年于武汉工程大学获得学士学位, 现就读于湖南师范大学, 主要研究方向为图像增强、目标检测。

E-mail: 2608598881@qq.com

Zou Yiwen received her B. Sc. degree from Wuhan Institute of Technology in 2022. Now she is a M. Sc. candidate in Hunan Normal University. Her main research interests include image enhancement and object detection.



卢笑, 2007 年于湖南大学获得学士学位, 2010 年于东南大学获得硕士学位, 2015 年于湖南大学获得博士学位, 现为湖南师范大学副教授, 主要研究方向为图像处理、领域自适应、大语言模型和图像增强。

E-mail: luxiao@hunnu.edu.cn

Lu Xiao received her B. Sc. degree from Hunan University in 2001, M. Sc. degree from Southeast University in 2010, and Ph. D. degree from Hunan University in 2015, respectively. Now she is an associate professor in Hunan Normal University. Her main research interests include image processing, domain adaptation, large language models and image enhancement.



汪鲁才(通信作者),1991 年于湖南大学获得学士学位,1996 年于湖南大学获得硕士学位,2006 年于湖南大学获得博士学位,现湖南师范大学教授,主要研究方向为图像处理与模式识别、语音信号处理、嵌入式系统及应用。

E-mail: wanglucai@hunnu.edu.cn

Wang Lucai (Corresponding author) received his B. Sc. degree from Hunan University in 1991, M. Sc. degree from Hunan University in 1996, and Ph. D. degree from Hunan University in 2006, respectively. Now he is a professor in Hunan Normal University. His main research interests include image processing and pattern recognition, speech signal processing, embedded systems and applications.



吴成中,2019 年于湖南大学获得博士学位,现湖南大学博士后,主要研究方向为人工智能、机器人、智能制造、机器视觉。

E-mail: wuchengzhong@hnu.edu.cn

Wu Chengzhong received his Ph. D degree in 2019. Now he is a postdoc in Hunan

University. His main research interests include Artificial Intelligence, Robotics, Intelligent Manufacturing, Machine Vision.



王耀南,1992 年于湖南大学获得硕士学位,1995 年于湖南大学获得博士学位,现湖南大学教授,主要研究方向为智能机器人技术、智能控制理论与应用、机器视觉感知与认知、智能化技术与系统和自主无人系统。

E-mail: yaonan@hnu.edu.cn

Wang Yaonan received his M. Sc. degree from Hunan University in 1992, and Ph. D. degree from Hunan University in 1995, respectively. Now he is a professor in Hunan University. His main research interests include Intelligent Robotics, Intelligent Control Theory and Applications, Machine Vision for Perception and Cognition, Intelligent Automation Technology and Systems and Autonomous Unmanned Systems.