Jinhong He hejh@stu.cqut.edu.cn Chongqing University of Technology Chongqing, China

> Mingliang Zhou mingliangzhou@cqu.edu.cn Chongqing University Chongqing, China

Minglong Xue* xueml@cqut.edu.cn Chongqing University of Technology Chongqing, China

Aoxiang Ning ningax@stu.cqut.edu.cn Chongqing University of Technology Chongqing, China Zhipu Liu zpliu@cqut.edu.cn Chongqing University of Technology Chongqing, China

Palaiahnakote Shivakumara S.Palaiahnakote@salford.ac.uk University of Salford Manchester, UK

Abstract

低光图像增强旨在提高退化图像的可视性, 以更好地与人类 视觉感知对齐。虽然基于扩散的方法由于其强大的生成能力 而显示出有希望的性能,但其单向退化建模往往难以捕捉真 实世界退化模式的复杂性,导致结构不一致和像素错位。为了 解决这些挑战,我们提出了一种双向扩散优化机制,该机制联 合建模低光和正常光图像的退化过程,从而实现更精确的退 化参数匹配和生成质量增强。具体来说,我们在训练过程中进 从低光到正常光以及从正常光到低光,并引 行双向扩散-入自适应特征交互块(AFI)以优化特征表示。通过利用这两 个路径之间的互补性,我们的方法对光照衰减和噪声分布施 加了隐含的对称约束,促进一致的退化学习并提高模型感知 光照和细节退化的能力。此外,我们设计了反射感知校正模块 (RACM),以在去噪后引导颜色恢复并抑制过曝区域,确保内 容一致性并生成与人类视觉感知匹配的高质量图像。在多个 基准数据集上的广泛实验表明,我们的方法在定量和定性评 估中均优于最先进的方法,同时能够有效地泛化到各种退化 场景。代码

CCS Concepts

 \bullet Computing methodologies \rightarrow Computational photography; Image processing.

Keywords

Low-light image enhancement, Diffusion models, Retinex prior

ACM Reference Format:

Jinhong He, Minglong Xue*, Zhipu Liu, Mingliang Zhou, Aoxiang Ning, and Palaiahnakote Shivakumara. 2025. 通过双向扩散实现低光图像增强的一致退化学习. In Proceedings of the 33rd ACM International Conference on Multimedia (MM '25), October 27-31, 2025, Dublin, Ireland. ACM, New York, NY, USA, 9 pages. https://doi.org/10.1145/nnnnnnnnnn



Figure 1: 我们的方法与其他竞争方法在低光图像增强任务上 的比较。我们的方法在色彩保真度上表现更佳,并能生成逼真 的纹理。最佳查看方式是放大观察。

1 引言

在低光环境下,图像质量的退化构成了一项重大挑战,阻碍了 计算机视觉应用的发展。能见度降低、噪声干扰和颜色失真对 语义分割 [25]、目标检测 [50] 和文本检测 [52] 等关键任务产 生了严重影响。为了解决这个问题,低光图像增强(LLE)技术旨在通过建模从退化条件到正常光照的复杂转换,恢复具有 自然亮度、清晰细节和准确颜色的视觉信息丰富的图像。早期 的方法主要依赖于手工制作的先验,如直方图均衡化 [37] 和 Retinex 理论 [19],这些方法在某些场景下证明是有效的。然 而,这些方法高度依赖于手动设计的特征,限制了它们的泛化 能力。结果是,它们难以处理复杂的退化模式,常常导致亮度 不平衡、伪影放大和细节丢失。

近年来,深度学习在多目标协同优化中展现了显著优势,包括亮度恢复[1,54]、噪声抑制[12]和颜色校正[17,48]。通过

*Corresponding author.

Permission to make digital or hard copies of all or part of this work for personal or classroom use is granted without fee provided that copies are not made or distributed for profit or commercial advantage and that copies bear this notice and the full citation on the first page. Copyrights for components of this work owned by others than the author(s) must be honored. Abstracting with credit is permitted. To copy otherwise, or republish, to post on servers or to redistribute to lists, requires prior specific permission and/or a fee. Request permissions from permissions@acm.org. *MM '25, October 27–31, 2025, Dublin, Ireland.*

© 2025 Copyright held by the owner/author(s). Publication rights licensed to ACM. ACM ISBN 978-x-xxxx-x/YY/MM https://doi.org/10.1145/nnnnnn.nnnnnn



Figure 2: 去噪过程的部分可视化。去噪过程 (1) 表示通过单向扩散映射获得的结果,而去噪过程 (2) 显示通过双向扩散获得的优化 结果。

利用端到端特征学习和强大的非线性表示,这些方法为稳健的 视觉感知开辟了新的途径。然而,尽管现有方法 [23,40,62] 在 通过改进场景渲染增强图像方面取得了进展,它们往往难以 恢复精细细节并准确还原原始颜色,如图 1 (DMFourLLIE) 所 示。为克服这些局限性,探索了生成模型,如生成对抗网络 (GANs) [16,54] 和变分自编码器(VAEs) [9],以建立低光域 和正常光域之间的高质量映射。这些模型显著提高了感知质 量,进一步推动了对 LLIE 生成范式的研究。

扩散模型的兴起显著推动了低级视觉任务的发展,得益于 其强大的生成能力和稳定的性能。然而,许多现有的方法依 赖于从低光到正常光域的单向映射进行图像级分布建模,这 通常会引入退化偏差,导致颜色失真和结构不匹配,如图1所 示。此外,单向映射的限制阻碍了约束和先验知识的有效整 合,需要细致的训练调整。这可能导致模型过于专注于某些任 务或数据集,从而降低其在各种降级场景中的泛化能力。此 外,由于扩散模型中去噪过程的随机性,约束条件的质量直接 影响最终的图像质量。这引发了一个有趣的问题:既然图像 退化本质上是增强的逆过程,二者之间是否存在可以利用的 内在关联来指导增强过程?这种考虑促使我们探索两个扩散 过程的联合训练。如图2所示,我们可视化了去噪过程的一部 分,表明通过优化两个扩散过程,增强的图像表现出更细致的 内容细节和优越的整体质量。

受到此灵感的启发,我们提出了一种双向扩散优化机制,以 促进低光照域和正常光照域之间一致的退化域学习。通过捕 捉共享的退化因素,该机制增强了降噪和恢复性能。具体来 说,在训练过程中,我们进行双向扩散:从低光照到正常光 照(L2H),以及从正常光照到低光照(H2L)。为了进一步提 高特征表示,我们引入了自适应特征交互模块 (AFI),利用注 意力矩阵来优化特征融合。来自 L2H 和 H2L 路径的互补退化 理解在光照衰减和噪声分布上施加隐式对称约束,从而实现 更稳定和一致的退化参数学习。这提高了模型感知光照退化 和细节损失的能力,从而实现更稳健的恢复。此外,我们提出 反射感知校正模块 (RACM) 以增强颜色保真度。通过 Retinex 分解提取反射先验并基于反射图的固有特性构建颜色感知场, RACM 能更准确地恢复颜色,并有效定位和抑制过曝区域。如 图1所示,我们的方法显著改善了全局和局部对比度,减轻了 大区域的过度校正,并有效抑制了伪影和噪声放大的问题。大 量实验表明,我们的框架在不同场景中的普适性,并验证了其 相对于现有方法的优越性。

总体而言,本文的主要贡献可以总结如下:

- 我们提出了一种双向扩散优化机制,该机制联合建模低 光域和正常光域之间的前向和反向扩散。该方法利用它 们的互补性在光照衰减和噪声分布上施加对称约束,从 而增强退化感知和细节保留。此外,自适应特征交互块 进一步加强了特征表示。
- 我们进一步开发了一个反射感知校正模块(RACM),该 模块利用从 Retinex 分解中得出的反射图先验来指导去 噪后的颜色恢复。此外,它能够抑制过曝区域,确保内 容一致性,并生成更符合人类视觉感知的高质量图像。
- 大量实验表明,所提出的框架在各种场景中表现出强大的泛化能力,并优于现有的LLIE方法。

2 相关工作

2.1 低光照图像增强

低光照图像增强(LLIE)旨在逆转各种退化因素,恢复清晰自 然的图像。现有的方法可以大致分为传统的非学习方法 [5,7] 和基于深度学习的方法 [22, 43, 47, 62] 。传统方法包括直方图 均衡化 [35] 、伽马校正 [38] 和基于 Retinex 理论的增强方法 [33]。然而,这些方法依赖于人工设计的先验,限制了它们在 复杂光照条件下的建模能力,使得它们难以泛化,并且容易 放大噪声。近年来,得益于大规模数据集[41,44,56],深度学 习方法在 LLIE 任务中取得了显著进展。例如, RetinexNet [44] 应用 Retinex 理论进行图像分解, 但存在一些色彩偏移问题; SNRNet [48] 利用一个信噪比感知的变换器来提高色彩的稳定 性; CIDNet [53] 进一步引入 HVI 色彩空间来分离亮度和色度, 并通过双向注意机制增强色彩的保真度。此外,FourLLIE [40] 结合傅里叶变换以提高鲁棒性,而 DMFourLLIE [62] 采用双阶 段、多分支傅里叶设计来同时增强低光照图像的亮度、结构和 纹理细节。尽管在特定任务中表现良好,这些方法在适应复杂 的真实退化条件方面仍然存在局限性, 突显出对更具鲁棒性 的 LLIE 解决方案的需求。

2.2 图像修复扩散模型

近年来,对高质量图像恢复的需求不断增长,引起了对生成 模式的兴趣。扩散模型 [11,39] 通过优化变分界限以更好地匹 配目标分布,从而生成高质量的图像,被广泛应用于图像恢 复任务 [24,51,58]。例如,GDP [4]利用扩散先验生成逼真的 输出,而 IR-SDE [27] 构建随机微分方程来逆转图像退化,实 现显著的恢复性能。WeatherDiff [36] 使用基于局部补丁的扩 散模型来去除与天气相关的退化。在图像增强领域 [2,34,46],



Figure 3: 我们提出的方法的整体流程。首先,我们从输入的正常光照图像 X_h 和预定义的噪声水平 ā_t 生成噪声潜变量 x_t 。正常光 照图像 X_h 和低光照图像 X_l 分别作为 H2L(正常到低光照)和 L2H(低到正常光照)路径的条件约束。这些图像与 x_t 连接并输入 到一个 U-Net 中进行噪声预测。为了增强特征表示,我们引入了自适应特征交互(AFI)模块。在训练过程中,我们通过最小化 H2L 和 L2H 噪声估计之间的差异来优化 L2H 噪声估计网络,使其能够学习高质量的降级映射。最后,优化后的网络执行反向去 噪,将高斯噪声 x_t 转换为初始输出。这个输出通过反射感知校正模块(RACM)进行进一步的颜色和光照校正,最终生成增强图 像 I_E。

GSAD [12] 将全局正则化引入扩散过程中以增强低光图像,而 AnlightenDiff [2] 提出了一种动态调整的扩散锚定机制以确保 增强结果的真实性。最近的研究进一步探索了将物理先验结 合到扩散方法中。例如,LightenDiffusion [15] 将 Retinex 理论 整合到扩散模型的潜在空间中,以实现无监督的低光增强。同 样,Reti-Diff [8] 在潜在空间中提取反射和照明先验以指导图 像特征增强,从而提高增强质量。然而,现有方法通常采用单 向退化建模,这可能忽略某些退化参数,导致局部结构不匹配 和像素错位,最终影响最终恢复质量。关于该领域的综合回 顾,我们建议读者参考 [10]。

3 方法

条件扩散模型主要由两个步骤组成:前向扩散过程 q 和反向采 样过程 p_{θ} 。前向扩散过程旨在通过具有预定义方差计划 β_t 的 马尔科夫链生成一系列噪声潜在变量 x_1, x_2, \ldots, x_T 。由于在前 向过程中的噪声是独立的,并且遵循均值为 $\sqrt{1 - \beta_t} x_{t-1}$ 和方 差为 $\beta_t I$ 的正态分布,我们定义 $\alpha_t = 1 - \beta_t$ 和 $\tilde{\alpha}_t = \prod_{i=1}^t \alpha_i$ 。重 新定义后,前向扩散过程可以简化如下:

$$q(x_t|x_0) = \mathcal{N}(x_t; \sqrt{\bar{\alpha}_t} x_0, (1 - \bar{\alpha}_t)I), \tag{1}$$

其中 $t \in \{1, ..., T\}$ 。在反向扩散过程中,我们通过施加条件图像 y 的约束来迭代预测干净的图像 x_0 。反向扩散过程表示为:

$$p_{\theta}(x_{t-1}|x_t, y) = \mathcal{N}(x_{t-1}; \mu_{\theta}(x_t, y, \bar{\alpha}_t), \sigma_t^2 I).$$

$$(2)$$

在本节中,我们提出了一种双向扩散优化策略,旨在同时 建模低光和正常光图像的退化过程。该方法能够更精确地匹 配退化参数,从而提高生成质量。整体框架如图3所示。接下 来,我们将详细介绍所提方法的各个组成部分。

在训练过程中,退化参数的单向桥接可能导致某些细节的 丢失。为了解决这个问题,我们联合执行低光和正常光图像的 生成过程,从而更全面地建模图像退化与修复之间的潜在关 系。具体来说,在训练阶段,我们首先对输入的真实图像 *xh* 进行前向扩散,以获得一个纯噪声图像。然后,我们分别使用 正常光图像 x_h 和低光图像 x_l 作为 H2L 和 L2H 路径去噪过程 的条件约束。这些图像在输入 U-Net 进行噪声预测之前, 与噪 声图像进行拼接。与大多数基于扩散的方法相似, UNet 作为 噪声估计的主网络骨干 ϵ_{θ} 。然而,不同于现有的方法,我们 在 U-Net 的编码器部分的两个双向扩散去噪路径之间共享参 数。这种设计促进了共同特征的学习并增强了特征重用能力。 此外,我们在特定分辨率层引入了 AFI 模块,以进一步增强特 征表示。在上采样阶段,我们采用独立的解码器来学习每个路 径的独特退化噪声,以确保 L2H 和 H2L 路径的独立性。

相应地,在逆过程,我们遵循方程2,并利用扩散模型的 编辑和数据合成能力,以迭代方式优化L2H和H2L去噪路径, 从而获得高质量的无噪声输出。这个过程可以表示为:

$$I_E, I_D = p_\theta(x_{t-1}|x_t, y), \ y \in \{x_l, x_h\},$$
(3)

,其中 I_E 表示 L2H 扩散路径的去噪输出, I_D 表示 H2L 扩散路 径的去噪输出。在训练阶段,扩散模型的目标是优化网络参数 θ ,以确保从低光到正常光(L2H: $\epsilon_{\theta}(x_t, x_l, t)$)和从正常光到 低光(H2L: $\epsilon_{\theta}(x_t, x_h, t)$)路径的噪声估计接近标准高斯噪声, 从而生成高质量的增强输出。此外,我们的核心目标是优化 L2H 路径上的噪声估计网络,以提高增强效果。为了加强退化 一致性的学习,我们通过最小化 L2H 和 H2L 估计的噪声向量 之间的差异,隐式地对光照衰减和噪声分布施加对称约束,从 而实现高质量的映射。基于此,我们定义了优化扩散模型的目 标函数如下:

$$\mathcal{L}_{diff} = \| \epsilon_t - \epsilon_\theta(x_t, x_l, t) \|_2 + \| \bar{\epsilon}_t - \epsilon_{min} \|_2, \tag{4}$$

,其中 ϵ_t 表示在步骤 t 对于两个路径都使用的噪声差异 ϵ 。 $\epsilon_{min} = \epsilon_{\theta}(x_t, x_h, t) - \epsilon_{\theta}(x_t, x_l, t)$ 表示预测噪声的差异。

自适应特征交互:如图 3 所示,我们进一步在 UNet 的特定 分辨率层引入了自适应特征交互(AFI)模块,通过注意力矩 阵增强特征表示能力。该模块的核心思想是建立不同特征之 间的动态关系,从而加强 L2H 和 H2L 路径的特征信息。给定 输入特征 F_{in},我们首先应用 1×1 卷积层对特征进行投影,在



Figure 4: 我们提出的 RACM 的详细架构。

降低计算复杂度的同时增强表达能力。然后,我们将投影的特征展平以生成查询(Q)、键(K)和值(V)。基于生成的Q和K,通过矩阵乘法计算注意力权重,并对V进行加权求和以获得增强的输出特征 F_{output} 。为了自适应调整双向路径的贡献,我们引入了一个可学习的权重 λ ,使得模型可以根据输入动态调整。这一过程可以被公式化为以下形式:

$$Q, K, V = Flatten(conv1(F_{in})),$$
(5)

$$F_{\text{output}} = \lambda \cdot softmax(QK^{T}) \cdot V + F_{in}.$$
 (6)

Retinex 理论表明, 原始图像可以分解为反射分量 R 和照明 分量 L, 并且 R 在不同的照明条件下保持一致。这可以表示 为:

$$I = R \odot L. \tag{7}$$

在实际应用中,消除光照效应的过程常常受到噪声干扰和 光照估计错误的阻碍,这可能导致反射图 R 的某些区域过曝。 大多数现有方法专注于重建 R 以保留内容细节和颜色一致性, 同时优化光照成分 L 以增强图像。然而,在复杂的现实场景 中,一些关键细节可能会隐藏在光照成分中,导致信息丢失和 图像质量下降。因此,在我们的方法中,使用反射图 R 作为先 验信息来引导内容和颜色的恢复,同时抑制曝露区域,似乎是 一个更合适的方向。

如图 4 所示,我们整合反射先验构建了反射感知校正模块 (RACM),该模块利用通道注意力(CA)和空间注意力(SA) 自适应地校正图像的亮度和颜色。具体来说,我们首先对输 入图像进行 Retinex 分解 $D(\cdot)$,以获得反射先验 R,它提供了 可靠的颜色和结构信息。然后,我们对输入图像和反射先验 R结合卷积和 ReLU 提取深度嵌入特征 F' 和 R'。基于提取的特 征,我们使用通道注意力区分真实的颜色信息与过曝噪声,并 相应地调整颜色信息如 R'' = CA(R' + F')。同时,我们对输入 图像特征 F'应用空间注意力,以增强对边缘和纹理等高频成 分的响应,防止因光照调整导致的局部模糊如 F'' = SA(F')。

接下来,我们结合通道注意力和空间注意力权重,并使用 Hadamard 乘法来优化输入图像特征(F'·F"·R"),在特征空 间内实现两种类型的自适应调整:增强非过曝标记的纹理丰 富区域的特征并提高全局颜色一致性,以及降低高曝光区域 的特征幅度。最后,通过卷积块重建特征维度后,我们获得了 一幅经过进一步校正和优化亮度与色彩的高质量图像。

3.1 网络优化

除了用于优化噪声估计网络的目标函数 L_{diff} 外,我们进一步考虑感知信息和区域差异,以在质和量上提高图像质量。我们的损失函数由四个关键组成部分构成:

$$\mathcal{L}_{total} = \omega_1 \mathcal{L}_{diff} + \omega_2 \mathcal{L}_{content} + \omega_3 \mathcal{L}_{structural}, \tag{8}$$

其中, ω 表示损失权重,经验设定为 $\omega_1, \omega_2, \omega_3 = [1, 0.3, 1]$ 。具体来说,结构损失 $\mathcal{L}_{structural} = (1 - SSIM(I_E, x_h))$ 表示 L2H 路径生成结果 I_E 与参考图像 x_h 之间的结构相似性损失。 $\mathcal{L}_{content}$

表示双向扩散中两个路径的最终生成结果与参考图像之间的 内容损失,旨在最小化生成图像与参考图像之间的内容差异:

$$\mathcal{L}_{content} = \sum_{l=0}^{4} \left(\tau_1 \| \Phi_l(I_E) - \Phi_l(x_h) \|_2 + \tau_2 \| \Phi_l(I_D) - \Phi_l(x_l) \|_2 \right),$$
(9)

其中, τ 表示 L2H 和 H2L 路径的内容损失权重, 我们将其设定 为 0.9 和 0.1 。 Φ_l 表示从 ResNet101 模型的 l 层提取的特征。

4 实验

4.1 实验设置

实现细节。我们使用 PyTorch 和 Adam 优化器在两块 NVIDIA RTX 3090 GPU 上训练我们的方法(1000 轮迭代,批量大小为 8,初始学习率为 2×10⁻⁴)。H2L 路径仅在训练期间使用,而在 推理时省略。训练结束后,仅需 10 步去噪就能实现高质量结 果。实验在 LOL-v1 [44]、LOL-v2-Real [55]、LOL-v2-Synthetic [55]、UHD-LL [22](配对)和 DICM [20]、LIME [7]、MEF [30] (未配对)数据集上进行,配对使用 PSNR、SSIM [42]、LPIPS [61],未配对评价使用 MUSIQ [18]。附录中包括额外的结果。

4.2 定量评估

我们通过使用其他方法的官方预训练模型并运行其公开代码 获得其定量结果。如表 1 所示,我们的方法始终显著优于所 有比较方法。具体来说,在 PSNR 评估方面,我们的方法在 LOL-v1 和 LOL-v2-合成数据集上分别取得了 0.632 dB 和 1.146 dB 的显著改善,同时在 LOL-v2-真实数据集上保持第二佳的表 现。在 SSIM 评估上,我们的方法表现优异,在所有数据集中 排名第一,在 LOL-v2-真实数据集上获得了 0.876 的杰出 SSIM 分数。此外,对于感知指标 LPIPS,我们的方法在所有数据集 中也取得了最佳成绩。为了进一步验证双向扩散的有效性,我 们在 UHD-LL 数据集上将我们的方法与基于扩散的方法进行 比较。如表 2 所示,我们的方法在所有指标上均取得了最佳表 现。这些令人印象深刻的结果表明,通过双向扩散进行优化能 够学习更精确的退化域映射,验证了我们策略在解决 LLIE 任 务中的有效性。

如表 3 所示,我们报告了对未配对数据集的评估结果。更高的 MUSIQ 得分表示图像的自然度和视觉质量更好。显然,我 们的方法在所有数据集上都获得了最佳的 MUSIQ 得分。这进 一步证明了我们方法的优越性和泛化能力。

图 5 呈现了配对数据集上的定性结果。与竞争方法的详细 比较显示,我们的方法表现出卓越的增强能力。具体而言, 以前的方法在整体对比度不佳和细节模糊方面存在不足。例 如,在 LOL-v1中,Reti-Diff和URetinexNet++显示出色彩失真, 而 AnlightenDiff则产生过度增亮的结果。尽管 DMFourLLIE 和 CIDNet 达到相对较好的增强效果,但它们的背景细节和 整体色彩清晰度仍然不如我们的方法,而我们的方法更接 近于真实值(GT)。在 LOL-v2-Real 中,几乎所有方法都存 在严重的色彩偏差,导致整体呈现绿 ish 对比。在 LOL-v2-Synthesis中,LightenDiffusion引入了噪声,导致图像模糊。此 外,AnlightenDiff 和 URetinexNet++在亮度不足和过度曝光问 题上挣扎。

此外,图6展示了在非配对数据集上的定性结果。Reti-Diff和URetinexNet++未能生成完全明亮的视觉结果,而GSAD和CIDNet导致严重的颜色失真。相较之下,我们的方法保留了丰富的细节并有效缓解了颜色差异,实现了与GT十分接近的视觉效果。更多细节见附录。

Table 1: 我们的方法与其他 SOTA 方法在 LOL-v1 [44]、LOL-v2-Real [56] 和 LOL-v2-Syn [56] 数据集上的定量比较。↑(↓)表示 更大(更小)的值代表更好的质量。最佳和次佳性能分别用 <u>红色</u>和 蓝色 标出。请注意,在评估所有方法时,没有使用 GT Mean 进行整体亮度调整。

Mathada	Defense	LOL-v1			LOL-v2-Real			LOL-v2-Syn		
Methods	Reference	PSNR↑	SSIM ↑	LPIPS↓	PSNR ↑	SSIM ↑	LPIPS 🕽	PSNR ↑	SSIM ↑	LPIPS ↓
DRBN [55]	CVPR'20	19.774	0.827	0.317	19.730	0.819	0.252	21.627	0.825	0.174
MIRNet [60]	ECCV'20	22.122	0.830	0.250	20.021	0.820	0.233	22.520	0.899	0.110
Zero-DCE++ [21]	TPAMI'21	14.682	0.472	0.407	17.461	0.490	0.427	17.712	0.815	0.168
EnlightenGAN [16]	TIP'21	17.483	0.651	0.390	18.641	0.675	0.379	18.177	0.793	0.212
Kind++ [63]	IJCV'21	21.300	0.823	0.207	20.590	0.829	0.266	21.170	0.881	0.267
SCI [31]	CVPR'22	14.784	0.526	0.392	17.304	0.540	0.345	18.577	0.765	0.243
SNRnet [48]	CVPR'22	24.309	0.841	0.262	21.480	0.849	0.237	24.138	0.927	0.085
UHDFour [22]	ICLR'23	23.095	0.822	0.259	21.785	0.854	0.291	23.640	0.900	0.097
PairLIE [6]	CVPR'23	19.735	0.776	0.357	20.357	0.782	0.317	19.074	0.794	0.230
SMG-LLIE [49]	CVPR'23	24.306	0.813	0.281	22.625	0.824	0.287	25.622	0.870	0.194
GDP [4]	CVPR'23	15.904	0.540	0.431	14.290	0.493	0.435	16.127	0.593	0.279
PyDiff [64]	IJCAI'23	23.298	0.858	0.215	23.364	0.834	0.208	25.126	0.917	0.098
CLIP-LIT [23]	ICCV'23	12.394	0.493	0.397	15.262	0.601	0.398	16.190	0.772	0.200
Retinexformer [1]	ICCV'23	25.153	0.845	0.246	22.797	0.840	0.334	25.668	0.930	0.073
NeRco [54]	ICCV'23	22.946	0.785	0.311	19.234	0.671	0.338	19.628	0.799	0.263
Diff-Retinex [57]	ICCV'23	22.690	0.853	0.191	21.190	0.833	0.271	24.336	0.921	0.061
FourLLIE [40]	ACM MM'23	24.150	0.840	0.241	22.340	0.841	0.233	24.650	0.919	0.099
DiffLL [14]	TOG'23	26.316	0.844	0.219	22.428	0.817	0.191	25.456	0.896	0.102
GSAD [12]	NeurIPS'23	23.224	0.855	0.193	20.177	0.847	0.205	24.098	0.927	0.073
AnlightenDiff [2]	TIP'24	21.762	0.811	0.252	20.423	0.825	0.267	20.581	0.874	0.146
FourierDiff [29]	CVPR'24	17.560	0.607	0.359	18.673	0.602	0.362	13.699	0.631	0.252
LightenDiffusion [15]	ECCV'24	20.188	0.814	0.316	21.097	0.847	0.305	21.542	0.866	0.188
DMFourLLIE [62]	ACM MM'24	24.754	0.859	0.195	22.974	0.859	0.187	25.937	0.933	0.081
URetienxNet++ [45]	TPAMI'25	23.826	0.839	0.231	21.967	0.836	0.203	24.603	0.927	0.102
Reti-Diff [8]	ICLR'25	25.132	0.866	0.199	22.987	0.859	0.186	27.530	0.951	0.053
CIDNet [53]	CVPR'25	23.809	0.857	0.188	24.111	0.868	0.202	25.129	0.939	0.070
Ours	-	26.948	0.869	0.184	23.371	0.876	0.181	28.676	0.953	0.049



Figure 5: 在 LOL-v1、LOL-v2-real 和 LOL-v2-Synthesis 数据集上的视觉比较。我们提出的方法在增强可见度的同时,有效保持 了卓越的图像细节和原始颜色。放大查看效果最佳。

为了进一步评估我们方法的泛化能力,我们在各种低级别 视觉任务上进行了跨任务验证。具体而言,我们将模型应用于 超出低光照图像增强的任务,例如在 CBSD68 数据集上的图像 去噪和在 CelebA-HQ 数据集上的图像修复。CBSD68 [32] 包含 68 张用于去噪的图像,其中加入了噪声水平为 50 的高斯噪声。



Figure 6: 在未配对的数据集 DICM、LIME 和 MEF 上的视觉比较。放大查看效果最佳。

Table 2: 在 UHD-LL [22] 数据集上与基于扩散的方法进行定量比较。

	UHD-LL					
Methods	PSNR↑	SSIM↑	LPIPS↓	Param (M)		
PyDiff [64]	26.643	0.907	0.153	97.9		
DiffLL [14]	25.843	0.863	0.237	22.1		
Diff-Retinex [57]	26.590	0.897	0.155	56.9		
GSAD [12]	26.771	0.901	0.178	17.4		
AnlightenDiff [2]	24.972	0.881	0.186	37.8		
FourierDiff [29]	18.084	0.781	0.225	547.5		
LightenDiffusion [15]	23.854	0.864	0.187	27.8		
Reti-Diff [8]	26.917	0.905	0.138	26.1		
Ours	28.052	0.923	0.105	33.5		



Figure 7: 在图像修复和图像去噪任务中与基于扩散的方法 IR-SDE 的视觉比较。放大查看效果最佳。

CelebA-HQ [13] 使用 100 张图像通过薄面具分割进行评估,依据的是 RePaint [26] 的设置。

如表 4 所示,实验结果表明我们的方法在不同任务中达到 了竞争性表现。这表明双向扩散优化能够有效地学习稳健的 特征映射,使得我们的模型能够很好地泛化到多个图像复原 任务。此外,如图 7 所示,我们将我们的方法与基于扩散的方 Table 3: MUSIQ 在 DICM [20]、LIME [7] 和 MEF [30] 数据 集上的评分。更高的分数表示更好的质量。最佳和次佳表现 分别用 <u>红色</u> 和 蓝色 标记。"AVG"表示这三个数据集的平均 MUSIQ 分数。

Methods	DICM	MEF	LIME	AVG
SNRNet [48]	53.594	56.920	52.165	54.226
CLIP-Lit [23]	63.072	62.357	62.865	62.765
UHDFour [22]	59.238	59.419	58.125	58.927
GDP [4]	55.608	58.978	57.300	57.295
Diff-Retinex [57]	61.853	61.089	60.422	61.121
DiffLL [14]	58.264	62.601	57.617	59.494
GSAD [12]	59.876	57.649	58.755	58.760
FourierDiff [29]	57.118	57.405	56.829	57.117
LightenDiffusion [15]	55.812	58.669	61.147	58.543
DMFourLLIE [62]	61.795	61.529	63.723	62.349
URetienxNet++ [45]	62.334	60.330	62.056	61.573
Reti-Diff [8]	62.656	62.814	63.376	62.949
CIDNet [53]	59.512	62.794	59.008	60.438
Ours	63.186	63.022	64.503	63.570

Table 4: 对 CelebA-HQ 数据集上的图像修补和 BSD68 数据集上的去噪进行定量比较。

]	Inpainting	g	Denoising			
Methods	PSNR ↑	SSIM ↑	LPIPS ↓	PSNR ↑	SSIM ↑	LPIPS ↓	
Restormer [59]	29.881	0.914	0.070	27.246	0.762	0.215	
NAFNet [3]	29.731	0.907	0.085	27.160	0.768	0.216	
IR-SDE [27]	27.557	0.884	0.061	24.821	0.640	0.232	
DA-CLIP [28]	29.277	0.901	0.042	24.333	0.571	0.269	
Ours	30.712	0.927	0.040	27.258	0.788	0.198	

法 IR-SDE 进行了比较。结果显示我们的方法在视觉感知质量 上取得了更优的表现。



Figure 8: 所提方法中组件消融的可视化。完整集表现最佳。同时, PSNR 和 SSIM 均显示出显著的提升,强调了它们在图像 增强中的重要性。

Table 5: 在 LOL-v1 数据集上进行不同模型设置的消融研究。 "H2L" 表示使用正常光到低光路径进行双向扩散。"Default" 表示完整的模型设置。

index	H2L	AFI	RACM	PSNR↑	SSIM↑	LPIPS↓
# 1	X	Х	Х	23.577	0.835	0.211
# 2	\checkmark	Х	Х	25.648	0.858	0.193
# 3	\checkmark	\checkmark	X	26.163	0.861	0.190
Default	\checkmark	\checkmark	✓	26.948	0.869	0.184

4.3 消融研究

不同成分的有效性。在 LOL-v1 数据集上的消融实验中,我们 验证了它们的有效性。如表5所示,其中,#1表示没有任何修 改的基本设置。#2引入了用于双向扩散的正常光到低光(H2L) 路径。#3进一步结合了自适应特征交互(AFI)模块。#4采 用完整配置。我们观察到,与基准设置#1相比,#2在PSNR 和 SSIM 评估中取得了显著的性能提升,分别提高了 2.071 dB 和 0.23。这表明双向扩散策略在退化学习中的必要性。为了进 一步增强特征表示,我们采用配置 #3,进一步优化模型性能。 最后,通过 RACM,我们获得了最完整的配置,并达到了最佳 的评估结果。具体而言,与#3相比,它进一步提高了 PSNR 和 SSIM 得分, 分别为 0.785 dB 和 0.08, 同时也在 LPIPS 中的 感知度量上有所改进。这突显了 RACM 组件在颜色和光照校 正中的关键作用。此外,图8中的视觉结果为每个组件的有效 性提供了额外的验证。例如,在结合双向扩散策略(#2)后, 图像在色彩保真度和细节保留方面显示出显著改进。通过 AFI 和 RACM 模块引入的进一步优化和校正, 增强后的图像逐渐 实现了视觉上的友好优化。

我们通过系统地去除每个组件并在表格 6 中报告定量结果 来验证所提出损失函数的有效性。如第二列所示,去除扩散损 失 *L*_{diff} 会显著降低模型性能,突显其在生成质量中的关键作 用以及双向扩散策略的重要性。内容损失 *L*_{content} 在生成的图 像中导致显著变化,尤其在失真指标方面,其中 PSNR 和 SSIM 分别提高 1.571 dB 和 0.16。结构损失 *L*_{structural} 的设计是为了 进一步帮助重建图像细节和稳定基于扩散的内容生成;因此, 去除它会导致性能下降。

Table 6: 损失函数项的消融研究。

	Loss Settings						
Metrics	w/o \mathcal{L}_{diff}	w/o $\mathcal{L}_{content}$	w/o $\mathcal{L}_{structural}$	Default			
PSNR ↑	25.648	25.378	26.643	26.948			
SSIM ↑	0.851	0.853	0.857	0.869			
LPIPS ↓	0.207	0.213	0.187	0.184			

在本文中,我们提出了一种新颖的双向扩散优化机制用于 低光图像增强。通过联合建模低光和正常光域之间的扩散过 程,我们的方法隐式地在光照衰减和噪声分布上建立了对称 约束,从而实现更精确的退化参数估计和改进的细节保留。此 外,我们引入了自适应特征交互模块以增强特征表示,并设计 了一个反射感知校正模块(RACM)以精细化色彩恢复,同时 有效抑制过曝光伪影。在多个基准数据集上进行的大量实验 表明,我们的方法是有效的,展示了无论是在定量评估还是在 定性评估中,它都能够持续优于最先进的方法。此外,我们的 框架在不同退化场景下的强大泛化能力突显了其在实际应用 中的潜力。

Acknowledgments

This work was supported in part by the National Natural Science Foundation of China under Grant 62176027; the Science and Technology Research Program of Chongqing Municipal Education Commission, China (Grant No. KJQN202401106); the Chongqing Talent under Grant, China (cstc2024ycjh-bgzxm0082); the Central University Operating Expenses under Grant, China (2024CDJGF-044).

References

- Yuanhao Cai, Hao Bian, Jing Lin, Haoqian Wang, Radu Timofte, and Yulun Zhang. 2023. Retinexformer: One-stage retinex-based transformer for low-light image enhancement. In Proceedings of the IEEE/CVF international conference on computer vision. 12504–12513.
- [2] Cheuk-Yiu Chan, Wan-Chi Siu, Yuk-Hee Chan, and H. Anthony Chan. 2024. AnlightenDiff: Anchoring Diffusion Probabilistic Model on Low Light Image Enhancement. *IEEE Transactions on Image Processing* 33 (2024), 6324–6339. https://doi.org/10.1109/TIP.2024.3486610
- [3] Liangyu Chen, Xiaojie Chu, Xiangyu Zhang, and Jian Sun. 2022. Simple baselines for image restoration. In *European conference on computer vision*. Springer, 17– 33.
- [4] Ben Fei, Zhaoyang Lyu, Liang Pan, Junzhe Zhang, Weidong Yang, Tianyue Luo, Bo Zhang, and Bo Dai. 2023. Generative Diffusion Prior for Unified Image Restoration and Enhancement. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 9935–9946.
- [5] Xueyang Fu, Delu Zeng, Yue Huang, Xiao-Ping Zhang, and Xinghao Ding. 2016. A weighted variational model for simultaneous reflectance and illumination estimation. In Proceedings of the IEEE conference on computer vision and pattern recognition. 2782–2790.
- [6] Zhenqi Fu, Yan Yang, Xiaotong Tu, Yue Huang, Xinghao Ding, and Kai-Kuang Ma. 2023. Learning a simple low-light image enhancer from paired low-light instances. In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 22252–22261.
- [7] Xiaojie Guo, Yu Li, and Haibin Ling. 2016. LIME: Low-light image enhancement via illumination map estimation. *IEEE Transactions on image processing* 26, 2 (2016), 982–993.
- [8] Chunming He, Chengyu Fang, Yulun Zhang, Tian Ye, Kai Li, Longxiang Tang, Zhenhua Guo, Xiu Li, and Sina Farsiu. 2023. Reti-diff: Illumination degradation image restoration with retinex-based latent diffusion model. arXiv preprint arXiv:2311.11638 (2023).
- [9] Chunming He, Kai Li, Yachao Zhang, Yulun Zhang, Chenyu You, Zhenhua Guo, Xiu Li, Martin Danelljan, and Fisher Yu. 2024. Strategic Preys Make Acute Predators: Enhancing Camouflaged Object Detectors by Generating Camouflaged Objects. In *ICLR*.
- [10] Chunming He, Yuqi Shen, Chengyu Fang, Fengyang Xiao, Longxiang Tang, Yulun Zhang, Wangmeng Zuo, Zhenhua Guo, and Xiu Li. 2025. Diffusion models

in low-level vision: A survey. IEEE Transactions on Pattern Analysis and Machine Intelligence (2025)

- [11] Jonathan Ho, Ajay Jain, and Pieter Abbeel. 2020. Denoising diffusion probabilistic models. Advances in neural information processing systems 33 (2020), 6840-
- [12] Jinhui Hou, Zhiyu Zhu, Junhui Hou, Hui Liu, Huanqiang Zeng, and Hui Yuan. 2024. Global structure-aware diffusion process for low-light image enhancement. Advances in Neural Information Processing Systems 36 (2024).
- [13] Huaibo Huang, Ran He, Zhenan Sun, Tieniu Tan, et al. 2018. Introvae: Introspective variational autoencoders for photographic image synthesis. Advances in neural information processing systems 31 (2018).
- [14] Hai Jiang, Ao Luo, Haoqiang Fan, Songchen Han, and Shuaicheng Liu. 2023. Lowlight image enhancement with wavelet-based diffusion models. ACM Transactions on Graphics (TOG) 42, 6 (2023), 1–14.
- [15] Hai Jiang, Ao Luo, Xiaohong Liu, Songchen Han, and Shuaicheng Liu. 2025. Lightendiffusion: Unsupervised low-light image enhancement with latent-retinex diffusion models. In European Conference on Computer Vision. Springer, 161-
- [16] Yifan Jiang, Xinyu Gong, Ding Liu, Yu Cheng, Chen Fang, Xiaohui Shen, Jianchao Yang, Pan Zhou, and Zhangyang Wang. 2021. Enlightengan: Deep light enhancement without paired supervision. IEEE transactions on image processing 30 (2021), 2340-2349.
- [17] Xin Jin, Ling-Hao Han, Zhen Li, Chun-Le Guo, Zhi Chai, and Chongyi Li. 2023. Dnf: Decouple and feedback network for seeing in the dark. In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 18135-18144.
- [18] Junjie Ke, Qifei Wang, Yilin Wang, Peyman Milanfar, and Feng Yang. 2021. Musiq: Multi-scale image quality transformer. In Proceedings of the IEEE/CVF international conference on computer vision, 5148-5157.
- [19] Edwin H Land and John J McCann. 1971. Lightness and retinex theory. Josa 61, 1 (1971), 1-11.
- [20] Chulwoo Lee, Chul Lee, and Chang-Su Kim. 2013. Contrast enhancement based on layered difference representation of 2D histograms. IEEE transactions on image processing 22, 12 (2013), 5372-5384.
- [21] Chongyi Li, Chunle Guo, and Chen Change Loy. 2021. Learning to enhance low-light image via zero-reference deep curve estimation. IEEE Transactions on Pattern Analysis and Machine Intelligence 44, 8 (2021), 4225-4238.
- [22] Chongyi Li, Chun-Le Guo, Man Zhou, Zhexin Liang, Shangchen Zhou, Ruicheng Feng, and Chen Change Loy. 2023. Embedding fourier for ultra-high-definition low-light image enhancement. arXiv preprint arXiv:2302.11831 (2023).
- [23] Zhexin Liang, Chongyi Li, Shangchen Zhou, Ruicheng Feng, and Chen Change Loy. 2023. Iterative prompt learning for unsupervised backlit image enhancement. In Proceedings of the IEEE/CVF International Conference on Computer Vision. 8094-8103.
- [24] Xinqi Lin, Jingwen He, Ziyan Chen, Zhaoyang Lyu, Bo Dai, Fanghua Yu, Yu Qiao, Wanli Ouyang, and Chao Dong. 2024. Diffbir: Toward blind image restoration with generative diffusion prior. In European Conference on Computer Vision. Springer, 430-448.
- [25] Wenxi Liu, Jiaxin Cai, Qi Li, Chenyang Liao, Jingjing Cao, Shengfeng He, and Yuanlong Yu. 2024. Learning Nighttime Semantic Segmentation the Hard Way. ACM Transactions on Multimedia Computing, Communications and Applications 20, 7 (2024), 1-23.
- [26] Andreas Lugmayr, Martin Danelljan, Andres Romero, Fisher Yu, Radu Timofte, and Luc Van Gool. 2022. Repaint: Inpainting using denoising diffusion probabilistic models. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 11461-11471.
- [27] Ziwei Luo, Fredrik K Gustafsson, Zheng Zhao, Jens Sjölund, and Thomas B Schön. 2023. Image restoration with mean-reverting stochastic differential equations. arXiv preprint arXiv:2301.11699 (2023).
- [28] Ziwei Luo, Fredrik K Gustafsson, Zheng Zhao, Jens Sjölund, and Thomas B Schön. 2024. Controlling Vision-Language Models for Multi-Task Image Restoration. In International Conference on Learning Representations.
- [29] Xiaoqian Lv, Shengping Zhang, Chenyang Wang, Yichen Zheng, Bineng Zhong, Chongyi Li, and Liqiang Nie. 2024. Fourier Priors-Guided Diffusion for Zero-Shot Joint Low-Light Enhancement and Deblurring. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 25378-25388.
- [30] Kede Ma, Kai Zeng, and Zhou Wang. 2015. Perceptual quality assessment for multi-exposure image fusion. IEEE Transactions on Image Processing 24, 11 (2015), 3345-3356.
- [31] Long Ma, Tengyu Ma, Risheng Liu, Xin Fan, and Zhongxuan Luo. 2022. Toward fast, flexible, and robust low-light image enhancement. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 5637-5646.
- [32] David Martin, Charless Fowlkes, Doron Tal, and Jitendra Malik. 2001. A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics. In Proceedings eighth IEEE international conference on computer vision. ICCV 2001, Vol. 2. IEEE, 416-423.
- [33] Michael K Ng and Wei Wang. 2011. A total variation model for retinex. SIAM Journal on Imaging Sciences 4, 1 (2011), 345–365. Aoxiang Ning, Minglong Xue, Jinhong He, and Chengyun Song. 2025. KAN see
- [34] in the dark. IEEE Signal Processing Letters (2025).

- [35] Chen Hee Ooi and Nor Ashidi Mat Isa. 2010. Quadrants dynamic histogram equalization for contrast enhancement. IEEE Transactions on Consumer Electronics 56, 4 (2010), 2552-2559.
- Ozan Özdenizci and Robert Legenstein. 2023. Restoring vision in adverse [36] weather conditions with patch-based denoising diffusion models. IEEE Transactions on Pattern Analysis and Machine Intelligence (2023).
- [37] Etta D Pisano, Shuquan Zong, Bradley M Hemminger, Marla DeLuca, R Eugene Johnston, Keith Muller, M Patricia Braeuning, and Stephen M Pizer. 1998. Contrast limited adaptive histogram equalization image processing to improve the detection of simulated spiculations in dense mammograms. Journal of Digital imaging 11 (1998), 193-200.
- [38] Shanto Rahman, Md Mostafijur Rahman, Mohammad Abdullah-Al-Wadud, Golam Dastegir Al-Quaderi, and Mohammad Shoyaib. 2016. An adaptive gamma correction for image enhancement. EURASIP Journal on Image and Video Processing 2016 (2016), 1-13.
- [39] Jiaming Song, Chenlin Meng, and Stefano Ermon. 2020. Denoising diffusion implicit models. arXiv preprint arXiv:2010.02502 (2020).
- [40] Chenxi Wang, Hongjun Wu, and Zhi Jin. 2023. Fourllie: Boosting low-light image enhancement by fourier frequency information. In Proceedings of the 31st ACM International Conference on Multimedia. 7459-7469.
- [41] Ruixing Wang, Xiaogang Xu, Chi-Wing Fu, Jiangbo Lu, Bei Yu, and Jiaya Jia. Seeing dynamic scene in the dark: A high-quality video dataset with 2021. mechatronic alignment. In Proceedings of the IEEE/CVF international conference on computer vision. 9700-9709.
- [42] Zhou Wang, Alan C Bovik, Hamid R Sheikh, and Eero P Simoncelli. 2004. Image quality assessment: from error visibility to structural similarity. IEEE transactions on image processing 13, 4 (2004), 600-612.
- [43] Zhen Wang, Dongyuan Li, Guang Li, Ziqing Zhang, and Renhe Jiang. 2024. Multimodal low-light image enhancement with depth information. In Proceedings of the 32nd ACM International Conference on Multimedia. 4976-4985.
- [44] Chen Wei, Wenjing Wang, Wenhan Yang, and Jiaying Liu. 2018. Deep retinex decomposition for low-light enhancement. arXiv preprint arXiv:1808.04560 (2018).
- Wenhui Wu, Jian Weng, Pingping Zhang, Xu Wang, Wenhan Yang, and Jianmin [45] Jiang. 2025. Interpretable Optimization-Inspired Unfolding Network for Low-Light Image Enhancement. IEEE Transactions on Pattern Analysis and Machine Intelligence (2025).
- Yuhui Wu, Guoqing Wang, Zhiwen Wang, Yang Yang, Tianyu Li, Malu Zhang, [46] Chongyi Li, and Heng Tao Shen. 2024. JoReS-Diff: Joint Retinex and Semantic Priors in Diffusion Model for Low-light Image Enhancement. In Proceedings of the 32nd ACM International Conference on Multimedia. 1810-1818.
- [47] Lintao Xu, Changhui Hu, Yin Hu, Xiaoyuan Jing, Ziyun Cai, and Xiaobo Lu. 2025. UPT-Flow: Multi-scale transformer-guided normalizing flow for low-light image enhancement. Pattern Recognition 158 (2025), 111076.
- [48] Xiaogang Xu, Ruixing Wang, Chi-Wing Fu, and Jiaya Jia. 2022. SNR-aware lowlight image enhancement. In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 17714–17724.
- [49] Xiaogang Xu, Ruixing Wang, and Jiangbo Lu. 2023. Low-Light Image Enhancement via Structure Modeling and Guidance. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 9893–9903.
- [50] Xin Xu, Shiqin Wang, Zheng Wang, Xiaolong Zhang, and Ruimin Hu. 2021. Exploring image enhancement for salient object detection in low light images. ACM transactions on multimedia computing, communications, and applications (TOMM) 17, 1s (2021), 1-19.
- [51] Minglong Xue, Jinhong He, Shivakumara Palaiahnakote, and Mingliang Zhou. 2025. Unified image restoration and enhancement: Degradation calibrated cycle reconstruction diffusion model. Pattern Recognition (2025), 112073.
- [52] Minglong Xue, Palaiahnakote Shivakumara, Chao Zhang, Yao Xiao, Tong Lu, Umapada Pal, Daniel Lopresti, and Zhibo Yang. 2020. Arbitrarily-oriented text detection in low light natural scene images. IEEE Transactions on Multimedia 23 (2020), 2706-2720.
- [53] Qingsen Yan, Yixu Feng, Cheng Zhang, Guansong Pang, Kangbiao Shi, Peng Wu, Wei Dong, Jinqiu Sun, and Yanning Zhang. 2025. HVI: A New color space for Low-light Image Enhancement. arXiv preprint arXiv:2502.20272 (2025)
- [54] Shuzhou Yang, Moxuan Ding, Yanmin Wu, Zihan Li, and Jian Zhang. 2023. Implicit neural representation for cooperative low-light image enhancement. In Proceedings of the IEEE/CVF International Conference on Computer Vision. 12918-12927.
- [55] Wenhan Yang, Shiqi Wang, Yuming Fang, Yue Wang, and Jiaying Liu. 2020. From fidelity to perceptual quality: A semi-supervised approach for low-light image enhancement. In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 3063-3072.
- [56] Wenhan Yang, Wenjing Wang, Haofeng Huang, Shiqi Wang, and Jiaying Liu. 2021. Sparse gradient regularized deep retinex network for robust low-light image enhancement. IEEE Transactions on Image Processing 30 (2021), 2072-
- [57] Xunpeng Yi, Han Xu, Hao Zhang, Linfeng Tang, and Jiayi Ma. 2023. Diff-retinex: Rethinking low-light image enhancement with a generative diffusion model. In

Proceedings of the IEEE/CVF International Conference on Computer Vision. 12302–12311.

- [58] Zongsheng Yue, Jianyi Wang, and Chen Change Loy. 2024. Efficient diffusion model for image restoration by residual shifting. *IEEE Transactions on Pattern Analysis and Machine Intelligence* (2024).
- [59] Syed Waqas Zamir, Aditya Arora, Salman Khan, Munawar Hayat, Fahad Shahbaz Khan, and Ming-Hsuan Yang. 2022. Restormer: Efficient transformer for high-resolution image restoration. In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 5728–5739.
- [60] Syed Waqas Zamir, Aditya Arora, Salman Khan, Munawar Hayat, Fahad Shahbaz Khan, Ming-Hsuan Yang, and Ling Shao. 2020. Learning enriched features for real image restoration and enhancement. In Computer Vision–ECCV 2020: 16th European Conference, Glasgow, UK, August 23–28, 2020, Proceedings, Part XXV 16. Springer, 492–511.
- [61] Richard Zhang, Phillip Isola, Alexei A Efros, Eli Shechtman, and Oliver Wang. 2018. The unreasonable effectiveness of deep features as a perceptual metric. In Proceedings of the IEEE conference on computer vision and pattern recognition. 586–595.
- [62] Tongshun Zhang, Pingping Liu, Ming Zhao, and Haotian Lv. 2024. DMFourLLIE: Dual-Stage and Multi-Branch Fourier Network for Low-Light Image Enhancement. In Proceedings of the 32nd ACM International Conference on Multimedia. 7434–7443.
- [63] Yonghua Zhang, Xiaojie Guo, Jiayi Ma, Wei Liu, and Jiawan Zhang. 2021. Beyond brightening low-light images. *International Journal of Computer Vision* 129 (2021), 1013–1037.
- [64] D Zhou, Z Yang, and Y Yang. 2023. Pyramid Diffusion Models for Low-light Image Enhancement. In International Joint Conference on Artificial Intelligence. IJCAI.