

中图法分类号: TP391.41 文献标识码: 文章编号: 1006-8961(XXXX)XX-0001-18

论文引用格式: Shao Tianxiang, Zhu Songhao, Liu Jiawei. Unsupervised Low-Light Image Enhancement via Illumination Curve Mapping and Structure-Preserving Denoising[J/OL]. Journal of Image and Graphics, XXXX: 1-18. DOI: 10.11834/jig.260221. (邵天翔, 朱松豪, 刘佳伟. 光照曲线映射与结构保留去噪的无监督低光照图像增强方法[J/OL]. 中国图象图形学报, XXXX: 1-18. DOI: 10.11834/jig.260221.) [DOI: 10.11834/jig.260221]

光照曲线映射与结构保留去噪的无监督低光照图像增强方法

邵天翔¹, 朱松豪¹, 刘佳伟²

1. 南京邮电大学 自动化学院 南京, 210023; 2. 华为技术有限公司, 广东深圳政企金融系统部 深圳, 518129

摘要: 针对低光照图像增强任务中缺乏先验约束导致细节丢失与色彩失真, 以及提亮易引发噪声放大等问题, 本文提出一种基于光照曲线映射与结构保留去噪的非配对无监督低光照图像增强方法。在生成阶段, 设计深层特征驱动的非线性光照曲线迭代映射机制, 提升细节增强能力并抑制色彩失真; 为保障曲线映射所需参数估计, 设计多尺度特征提取与抗噪卷积注意力, 缓解全局光照感知受限与噪声干扰参数估计问题; 设计结合零初始动态残差的半实例归一化机制, 抑制提亮导致噪声放大问题。在判别阶段, 采用全局-局部双分支架构联合监督图像宏观语义与微观纹理, 并提出通道映射一致性与曝光控制等多维联合约束损失。在此联合约束驱动下, 模型训练呈现规律性感知-失真演化, 据此提取双阶段模型(Ours-F与Ours-P)。实验结果表明, 在全参考LOLv2-Real数据集上, Ours-F模型取得峰值信噪比(peak signal-to-noise ratio, PSNR)为21.485dB、结构相似度(structural similarity, SSIM)为0.808以及学习感知图像块相似度(learned perceptual image patch similarity, LPIPS)为0.233, 其中PSNR与LPIPS取得了所列无监督方法中的最优值, 且SSIM达到次优水平; 在五个真实无参考测试集的横向对比中, Ours-P模型取得3.646的平均自然图像质量评价指标(natural image quality evaluator, NIQE)值优于多数对比方法。本方法在有效改善色偏与涂抹伪影的同时, 较好地恢复场景光影与真实结构。本文相关代码已开源, 获取地址: <https://cstr.cn/31253.11.sciencedb.j00240.00280>。

关键词: 低光照图像增强; 光照曲线映射; 结构保留去噪; 多维联合约束损失; 半实例归一化

Unsupervised Low-Light Image Enhancement via Illumination Curve Mapping and Structure-Preserving Denoising

Shao Tianxiang¹, Zhu Songhao¹, Liu Jiawei²

1. College of Automation, Nanjing University of Posts and Telecommunications, Nanjing 210023; 2. Huawei Technologies Co., Ltd., Government and Enterprise Financial System Department, Shenzhen Guangdong, 518129

Abstract: To address the issues of detail loss and color distortion caused by the lack of prior constraints, as well as noise amplification induced by brightening in low-light image enhancement, this paper proposes an unpaired unsupervised low-light image enhancement method based on illumination curve mapping and structure-preserving denoising. In the generation stage, a deep-feature-driven iterative nonlinear illumination curve mapping mechanism is designed to improve detail enhancement capabilities and suppress color distortion. To guarantee the parameter estimation required for curve mapping, a multi-scale feature extraction module and a noise-robust convolutional attention module are developed to alleviate the limitations of global illumination perception and noise interference during parameter estimation. Furthermore, a half-instance

normalization mechanism integrated with zero-initialized dynamic residuals is designed to suppress noise amplification caused by brightening. In the discriminator stage, a global-local dual-branch architecture is employed to jointly supervise the global illumination distribution and local textures of the image, and a multi-dimensional joint constraint loss, incorporating channel mapping consistency and exposure control, is formulated. Driven by these joint constraints, the model training exhibits a systematic perception-distortion evolution, from which two distinct models (Ours-F and Ours-P) are extracted. Experimental results demonstrate that on the full-reference LOLv2-Real dataset, the Ours-F model achieves a peak signal-to-noise ratio (PSNR) of 21.485 dB, a structural similarity (SSIM) of 0.808, and a learned perceptual image patch similarity (LPIPS) of 0.233, where the PSNR and LPIPS achieve the best performance among the listed unsupervised methods, and the SSIM reaches the second-best level. In evaluations across five real-world no-reference test sets, the Ours-P model achieves an average natural image quality evaluator (NIQE) of 3.646, outperforming most of the compared methods. The proposed method effectively alleviates color casts and smearing artifacts while successfully restoring the realistic illumination and structures of the scenes. The source code of this paper is publicly available at <https://cstr.cn/31253.11.sciencedb.j00240.00280>.

Key words: low-light image enhancement; illumination curve mapping; structure-preserving denoising; joint constraint loss; half instance normalization

论文引用格式: Shao Tianxiang, Zhu Songhao, Liu Jiawei. Unsupervised Low-Light Image Enhancement via Illumination Curve Mapping and Structure-Preserving Denoising [J/OL]. Journal of Image and Graphics. DOI:10.11834/jig.260221. (邵天翔, 朱松豪, 刘佳伟. 光照曲线映射与结构保留去噪的无监督低光照图像增强方法[J/OL]. 中国图象图形学报. DOI:10.11834/jig.260221.)

1 引言

在夜间、逆光、欠曝光等场景中采集的图像普遍存在光度偏低、对比度受损、噪声掩盖等退化现象。此类视觉特征退化不仅降低了图像视觉质量,还严重制约了目标检测、场景分割等下游计算机视觉任务的准确率与鲁棒性(Wang等,2020;Liu等,2021;Wang和Hoai,2018)此,低光照图像增强作为恢复图像清晰度与底层结构的前置处理技术,具备重要的学术研究与工程应用价值。

在暗弱光照条件下,图像获取终端在提升感光度时不可避免地会引入散粒噪声,导致获得的低光照图像呈现出亮度退化与噪声污染高度耦合的复杂状态。面对这种高度非线性的退化过程,传统方法(如直方图均衡化、Retinex理论,Pizer等,1987;Land,1977)由于过度依赖人工设计的先验假设与简化的物理光学模型,在处理复杂光照分布的真实夜景时,往往缺乏自适应调节能力,极易导致局部高光

区域过曝、暗部噪声放大、色彩偏移。近年来,基于有监督学习的深度神经网络(Wei等,2018;Chen等,2018)在客观评价指标上取得了显著进展,但其训练过程依赖严格配对的明暗图像数据;而采用合成数据训练的模型则因领域偏移问题,在处理真实夜景时常表现出泛化性不足(Jia等,2024;Wang等,2024)。为缓解对于配对数据的依赖,基于非配对数据的无监督生成对抗网络(如EnlightenGAN,Jiang等,2021)与零参考曲线映射方法(如Zero-DCE,Guo等,2020)相继提出。然而,前者通过端到端映射直接生成像素,缺乏约束,从而导致大幅提升亮度的同时也放大了噪声;后者虽利用非线性光照曲线降低过曝风险,但受限于极浅层网络架构,其全局特征提取能力有限,面对非均匀光照时难以实现精确映射,进而在明暗交界区域容易产生光晕伪影。

综上所述,现有方法在无监督零参考框架下,极暗区域提亮导致噪声放大,且现有全局平滑去噪方法在滤除噪声的同时,破坏图像微观纹理,导致涂抹伪影。针对上述难题,国内学者近期亦开展大量富有成效的探索,如利用非局部自相似性与外部生成先验构建内外双重互补约束,以平衡噪声去除与纹理保持(都双丽等,2023);或借助暗通道先验与最小通道约束图,构建照度与场景纹理注意力机制,有效引导暗区亮度提升与噪声抑制(赵明华等,2024)。然而,鉴于底层视觉任务中固有的感知-失真权衡(Blau和Michaeli,2018),单一网络参数难以在客观重构精度与主观视觉自然度同时达到最优。

为此,本文提出一种基于光照曲线映射与结构保留去噪的无监督低光照图像增强方法。为解决端到端框架由于缺乏先验约束导致细节丢失与色彩失真,引入深层语义驱动的非线性光照曲线迭代映射机制,提高细节保留度和视觉感知效果。针对特征传递中感受野受限与噪声干扰问题,设计多尺度特征提取模块(multi-scale feature extraction module, MSFEM)与抗噪卷积注意力模块(noise-robust convolutional block attention module, NRCBAM)以感知全局光照分布并净化特征,提高参数估计准确性与鲁棒性。为解决提亮导致噪声放大问题,本文受HINet(Chen等,2021)半实例归一化思想启发,设计结合零初始动态残差的半实例归一化机制,构建了结构保留去噪模块(structure-preserving denoising module, SPDM),实现自适应剥离噪点并保留纹理结构。此外,在联合先验约束的驱动下,模型在迭代中呈现规律性的感知-失真演化特征。据此,本文提取出分别侧重客观结构保真度与主观视觉自然度的双阶段模型,从而精准适配差异化下游评价基准。

本文的主要贡献归纳如下:

1) 提出一种深层语义驱动的非线性光照曲线映射机制。针对传统无监督网络端到端直接生成像素导致先验约束缺失易引发细节丢失与色彩失真的问题,引入光照曲线迭代映射机制。为确保曲线映射所需参数精准估计,设计多尺度特征提取与抗噪卷积注意力,克服全局光照感知受限与噪声干扰问题。

2) 设计了结合零初始动态残差与半实例归一化机制去噪模块。针对亮度增强易引发噪声放大,在网络输出端级联结构保留去噪模块。该机制通过半实例归一化对噪声进行滤除,消除暗区噪点与涂抹伪影的同时,保留并还原图像的真实纹理。

3) 构建了多维联合约束损失体系。创新性引入通道映射一致性、曝光控制、高维参数平滑、全局-局部特征自保持等多维联合约束损失,解决无监督学习指导不足问题,监督宏观语义与微观纹理,提高增强图像客观结构保真度与主观视觉自然度。

2 相关工作

低光照图像增强旨在恢复暗弱光照环境下图像的视觉质量与底层结构(吕宗旺等,2025;Li等,

2021;Tian等,2023)。根据技术演进的脉络与学习范式的不同,本文将从传统图像增强算法、有监督图像增强算法,以及无监督与零参考的图像增强算法三个维度,对现有图像增强研究进行梳理。

2.1 传统图像处理的增强算法

早期的暗弱光照图像增强主要基于传统图像处理技术,大致可分为基于空间域的映射算法和基于物理模型的算法。以直方图均衡化及其改进算法为代表的空间域方法,旨在通过拉伸图像灰度分布提高全局对比度(Zuiderveld,1994)。这类方法计算高效,但在处理光照分布极不均匀的复杂夜景图像时,由于未充分考虑局部相关性与结构信息连续性,极易导致光源区域过度曝光,并在拉伸灰度对比度时放大了隐藏噪声。

另一类经典算法则基于Retinex物理光学理论,其核心思想认为图像色彩取决于反射率。该类算法将退化图像分解为反映物体固有属性的反射分量和反映环境光照的照明分量,但这种分解本质上是一个高度病态逆问题。包括单尺度Retinex、多尺度Retinex、色彩恢复扩展(Land,1977;Jobson等,1997)等在内的算法,通过估计并平滑照明分量来实现亮度恢复与细节增强。在此基础上,为提升处理效率与结构保真度,Guo等人提出基于光照图估计的LIME算法(Guo等,2017),通过在光照分量上施加结构先验进行细化,取得显著视觉质量改善。

然而,上述传统算法通常高度依赖手工设计的先验假设与复杂的滤波参数。在面对多变且极端的真实光照场景时,此类算法缺乏灵活性,极易导致严重的色彩失真,或在明暗交界处产生明显的光晕伪影。传统方法在泛化性与鲁棒性上的固有局限,促使学术界逐渐将目光转向数据驱动的深度学习方法。

2.2 有监督图像增强算法

早期的探索(如LLNet,Lore等,2017)初步验证了神经网络在该任务中的可行性。随后,研究人员通过构建复杂卷积神经网络,学习正常-低光照图像间映射关系。例如,Chen等人利用提出的SID模型实现了从原始图像到标准红绿蓝色彩空间的端到端转换(Chen等,2018);Wei等人结合物理模型提出了Retinex-Net模型(Wei等,2018),在配对数据集上完成了光照与反射图的联合估计;Zhang等人构建了KinD模型(Zhang等,2019),通过光照比率调节进一

步提升了细节恢复能力。

然而,此类高度依赖配对的有监督算法在实际落地中面临着不可忽视的局限性:构建大规模且涵盖丰富场景的配对数据集极其困难。在真实场景中采集配对图像时,三脚架需保持相机绝对静止,并通过调节参数进行连续拍摄。这不仅极大地限制了数据采集场景的多样性,且环境光线的变化或画面中微小动态物体的存在,都会导致空间不对齐现象,进而引发模型训练时的伪影与模糊。为缓解数据匮乏,近期诸多研究(Jia 等,2024;Wang 等,2024)转向使用合成数据集进行对抗生成训练或循环一致性训练。但这不可避免引入域偏移问题,从而导致有监督模型在处理未见的真实复杂夜景时,泛化能力大幅衰减,极易在暗部生成不自然的涂抹与视觉伪影。

2.3 无监督与零参考的图像增强算法

为突破配对数据的局限,泛化能力更强的无监督与零参考算法逐渐成为主流。Jiang 等人提出的 EnlightenGAN 首次将无监督生成对抗网络引入低光照图像增强领域,有效提升了真实场景适用性。然而,现有方法多采用直接生成像素的端到端映射,缺乏先验约束,大幅提亮时极易局部过曝;且复杂的深层特征映射常会将底层暗噪声提取并放大。

另一方面,以 Zero-DCE 为代表的零参考方法利用自适应曲线映射代替像素生成,从数学底层有效降低了过曝与色彩漂移风险,SCI(Ma 等,2022)更将其推向极简的单层卷积。但为追求效率,此类方法多采用浅层局部卷积,感受野受限。面对极暗场景中边缘与散粒噪声高度耦合的复杂情况,缺乏全局语义感知的浅层网络不仅易在明暗交界处产生光晕伪影,对重度散粒噪声的处理性能也会显著衰减。

为解决极暗场景的噪声问题,近期研究开始引入显式去噪机制(如 Li 等人,2025 基于频域分离的联合架构)。然而,此类方法依赖繁琐的模块级联、外部先验及复杂的频域转换,大幅增加了优化难度与计算开销。此外,强力滤波难以在特征空间将散粒噪声与纹理有效剥离,全局平滑去噪极易导致高频细节丢失,使增强后的图像产生明显的“涂抹感”。

2.4 本文动机与分析

尽管无监督学习与零参考模型在低光照图像增强任务中取得显著进展,但在应对复杂暗光场景时仍面临三大挑战:

首先是语义感知与先验约束难以兼顾问题。传

统无监督生成对抗网络直接生成像素级图像,由于缺乏明确的先验约束,易导致色彩失真与细节丢失。相对而言,零参考曲线映射方法能够保证光照过渡的合理性,但此类方法通常使用浅层网络,缺乏特征提取能力,面对非均匀光照时参数估计易受干扰,产生光晕。因此,本文的首要动机在于摒弃传统的黑盒生成范式,将无监督对抗学习的深层特征提取能力与非线性光学规律相结合,利用深层语义网络驱动光照曲线映射,以保障增强过程的结构真实性与复杂场景下的鲁棒性。

其次是亮度提升导致噪声放大问题。现有无监督模型通常缺乏显式降噪设计,或仅依赖全局平滑损失抑制噪声。这种全局平滑降噪破坏纹理结构,导致增强结果出现明显涂抹感。针对这一挑战,本文致力于在无监督框架内解决“降噪伴随涂抹感”问题,旨在消除噪声的同时还原真实纹理细节。

最后是客观结构保真度与主观视觉自然度间的平衡问题。鉴于底层视觉任务中固有的感知-失真权衡,本文通过构建多维联合约束损失体系,挖掘感知-失真演化规律,以期在严格配对与无参考场景的差异化下游任务中,实现综合性能最优。

3 方法

本节将详细阐述提出的基于光照曲线映射与结构保留去噪的无监督低光照增强网络。首先,在 3.1 节中概述本文算法的整体框架;然后,在 3.2 节中深入探讨核心的参数估计生成器网络;最后,在 3.3 节与 3.4 节分别解析全局-局部双分支判别器的网络拓扑结构及多维联合约束损失函数优化目标。

3.1 方法框架

本文提出的 ICD-GAN (illumination curve and denoising generative adversarial network) 是一种面向低光照图像增强的无监督生成对抗网络,主要由光照曲线去噪生成器(ICD-Net)与全局-局部双分支判别器(GL-Disc)两部分构成。通过引入深层语义驱动的光照曲线映射与级联结构保留去噪机制,ICD-GAN 解决了传统无监督模型在先验约束缺失与提亮引发噪声放大问题。

由图 1 所示,与直接生成像素的传统生成网络不同,ICD-GAN 将图像增强任务分解为“光照参数估计”、“光照曲线映射”与“结构保留去噪”三个子

过程。




图1 本文所提出的 ICD-GAN 网络架构,该网络主要由光照曲线去噪生成器(ICD-Net)与全局-局部双分支判别器(GL-Disc)构成。

在生成阶段(ICD-Net):网络首先提取像素级光照注意力掩码,并将其与原始图像在通道维度拼接,作为生成器的四通道输入;随后,多尺度特征提取模块与抗噪卷积注意力模块实现全局光照感知与抗噪声干扰;接着,将获得的光照参数图与经伽马变换的注意力掩码进行逐像素相乘,实现光照参数的空间权重调制;进一步,利用该调制参数驱动非线性光照曲线,完成图像的迭代提亮;最后,在输出端级联结构保留去噪模块,消除迭代提亮中被放大的噪点。经过上述流程,模型最终可以实现亮度恢复与噪声抑制。

在判别阶段(GL-Disc):本文构建了全局-局部协同对抗学习机制。全局判别器旨在从宏观层面约束生成图像,确保其在全局亮度分布及色彩一致;局部判别器则针对随机裁剪的图像图块,以提升模型纹理恢复能力。

为权衡增强结果结构信息保真性与视觉层面感知性,本文构建了由全局-局部对抗损失、通道映射一致性损失、曝光控制损失、高维参数平滑损失及全局-局部特征自保持损失构成的多维联合优化目标。依托该联合约束损失与前述架构的优势,ICD-GAN能够在无监督训练的演化过程中,规律性地提取出强调客观结构保真度的模型(Ours-F)与强调主观视觉自然度的模型(Ours-P),从而精准适配全参考(如LOLv2-Real)与真实无参考等差异化的下游评测基准。

3.2 光照曲线去噪生成器网络

如图2所示,光照曲线去噪生成器包含非线性光照曲线映射过程与结构保留去噪过程。该网络利用两种不同形式的光照先验信息,分别用于特征提取和亮度重构。

参数估计生成器网络具体实现过程如下所述。首先,通过灰度化与亮度反转生成低照度图像的像素级光照注意力掩码,用于显式标示暗部区域。随后,将单通道注意力掩码与原始三通道特征上进行拼接,形成一个四通道张量,用以在特征提取初始阶段就能直接获取空间亮度分布先验知识。

与此同时,单通道注意力掩码经伽马变换生成非线性权重映射,对光照参数进行精确空间权重调制。最后,四通道张量经由 3×3 卷积、LeakyReLU、批量归一化(batch normalization, BN)成的卷积块映射至高维特征空间。

在编码阶段,为抑制散粒噪声在特征域中的累积,本文在每次下采样前级联多尺度特征提取模块(MSFEM)与抗噪卷积注意力模块(NRCBAM)。数据流向过程如下所述:首先,当前层特征进入多尺度特征提取模块,利用并行多尺度卷积捕获不同感受野下的上下文语义;随后,接入抗噪卷积注意力模块,通过通道残差机制对特征响应进行降噪。完成特征提取与降噪处理后,特征映射经步长为2的卷积层进行下采样。该编码架构有利于在特征传递早期阶段抑制背景存在的噪点,从而降低干扰信息向解码器传播风险。

在解码阶段,深层特征经由上采样恢复空间分辨率,并与编码器对应尺度特征映射进行通道拼接。逐层解码后获得的特征映射,经 1×1 卷积层与 Tanh 激活函数后,输出与原图分辨率一致的高维光照参数图。该张量沿通道维度均分为 n 阶独立的参数序列,在像素级光照注意力掩码调制下,驱动非线性光

照曲线对原图进行逐阶迭代映射,实现亮度空间自适应重构。

最后,迭代提亮后的图像序列被送入结构保留去噪模块。该模块在保持网络端到端可微前提下,对空域高频噪声进行处理并保真边缘结构,最终输出亮度恢复且画质纯净的增强图像。




图2 本文光照曲线去噪生成器(ICD-Net)的结构示意图。其核心组件包括:光照参数估计器、非线性光照曲线映射模块以及结构保留去噪模块。

3.2.1 多尺度特征提取模块




图3 多尺度特征提取模块的结构示意图,包括三个核心部件:用于提取多感受野上下文信息的多尺度并行卷积分支、自适应分配特征融合权重的动态通道门控机制、保留底层细节特征的全局残差连接。

在极端暗光图像中,微弱结构边缘常与复杂散粒噪声混杂,单一尺度感受野难以同时兼顾全局光照分布感知与局部高频细节恢复。为此,本文继承并扩展了 Li 等(2019)提出的选择性卷积核机制(selective kernel network, SKNet)的多感受野动态权衡思想,设计了如图3所示的多尺度特征提取模块,具体而言,本文将感受野扩展为三路空洞卷积分支;并借助前端融合的光照掩码,使动态门控机制能够依据局部光照先验自适应分配跨尺度权重,实现特征的精准融合。

多尺度特征提取模块具体实现过程如下所述。

首先,利用 1×1 卷积与 LeakyReLU 激活函数进行降维映射;然后,将特征映射并行送入三个分支进行多尺度特征提取:第一分支采用标准 3×3 卷积捕获局部微观纹理;第二、第三分支则分别采用膨胀率为 d_1 和 d_2 的空洞卷积,在不额外增加计算量前提下显著扩展感受野,有效捕捉远距离结构信息与长程上下文信息;其次,在获取多尺度特征后,为能根据局部纹理特征与光照分布信息自适应聚焦于最佳感受野,本文引入通道注意力动态门控融合策略(首先,对三路特征进行逐元素相加以初步聚合多尺度信息;然后,通过全局平均池化将聚合特征在空间维度上压缩为通道描述符,并将其送入由两层 1×1 卷积构成的特征瓶颈层,以学习各分支间的非线性通道相关性;最后,借鉴选择性卷积核机制的竞争性分配理念,利用 Softmax 函数沿分支维度进行归一化,生成对应三个并行分支的动态门控权重);接着,利用生成的权重对多尺度特征进行通道维度的逐元素乘法调制,并将调制后的特征重新聚合为联合特征;最后,利用 1×1 卷积进行特征平滑,并引入全局跳跃连接进行特征残差融合。

多尺度特征提取模块的最终特征映射可用下式表示:

$$\begin{cases} V_{\text{sum}} = W_1 \otimes U_1 + W_2 \otimes U_2 + W_3 \otimes U_3 \\ Y = \text{Shortcut}(X) + \text{Conv}_{3 \times 3}(V_{\text{sum}}) \end{cases} \quad (1)$$

式中, $\otimes$ 表示逐元素乘法, $\text{Shortcut}(\cdot)$ 表示残差对齐。

3.2.2 抗噪卷积注意力模块

针对极端暗光环境下结构边缘与散粒噪声混杂问题,传统注意力机制在增强特征时极易放大局部噪声。经典的卷积块注意力模块(convolutional block attention module, CBAM; Woo 等, 2018)虽能有效提取通道与空间的联合显著性特征,但其在空间维度上依赖单一尺度的池化与卷积,在处理极暗光真实图像时,常会将高频散粒噪声误判为结构边缘并予以同步放大。为此,本文进行结构改进,由图4所示结构示意图可知,与卷积块注意力模块的串行机制不同,本模块在空间注意力引入多尺度感受野并行处理,并构建跨空间残差回填架构。




图4 抗噪卷积注意力模块的结构示意图包括三个核心部件:用于构建特征基底的双路通道注意力机制、捕获多尺度空间细节的并行空间注意力分支,以及避免有效特征退化的跨越式残差回填架构。

抗噪卷积注意力模块具体实现过程如下所述。首先,在空间维度上并行执行全局平均池化与全局最大池化,分别聚合全局上下文信息与局部显著特征;随后,两路聚合特征并行送入共享多层感知机(由降维 1×1 卷积、ReLU 激活函数、升维 1×1 卷积构成)中,用以学习通道间非线性依赖关系;最后,两路输出逐元素相加后,经 Sigmoid 函数激活得到通道门控权重,再与输入特征 X 逐元素相乘,构建通道优化特征 F_{ca} :

$$\begin{cases} W_{ca} = \sigma \{ \text{MLP}[\text{AvgPool}(X)] + \text{MLP}[\text{MaxPool}(X)] \} \\ F_{ca} = X \otimes W_{ca} \end{cases} \quad (2)$$

在此基础上,为精准定位并提纯空间结构信息,沿通道维度分别计算特征图的平均值与最大值,并将两者拼接为双通道特征映射 F_{cat} ;随后,将 F_{cat} 并行输入三个不同感受野空间分支:第一分支采用 1×1 卷积聚焦像素级细节,第二分支采用 3×3 卷积捕获局部边缘,第三分支采用 5×5 卷积提取宏观平滑特征,其中每个分支内部均采用了“卷积-批量归一化-ReLU-降维 1×1 卷积”的特征瓶颈结构;最后,三路多尺度特征逐元素相加,并经 Sigmoid 激活后,生成空间注意力权重,再与特征 F_{ca} 逐元素相乘,提取跨尺度空间增量特征 F_{sa} :

$$\begin{cases} W_{sa} = \sigma [f_{1 \times 1}(F_{cat}) + f_{3 \times 3}(F_{cat}) + f_{5 \times 5}(F_{cat})] \\ F_{sa} = F_{ca} \otimes W_{sa} \end{cases} \quad (3)$$

式中, $f_{k \times k}(\cdot)$ 表示感受野为 $k \times k$ 的特征瓶颈操作。

为避免深层网络优化过程中串联注意力机制引发有效特征退化,本文引入残差机制,将多尺度空间增量特征 F_{sa} 与通道优化特征 F_{ca} 直接进行逐元素相乘,得到该模块最终输出 Y :

$$Y = F_{ca} + F_{sa} \quad (4)$$

3.2.3 融合像素级灰度掩码的光照曲线迭代映射

本文的光照恢复机制在数学底层上继承了 Zero-DCE 的可微曲线调节策略,此类方法通过估计全局或局部曲线映射参数调整图像亮度动态范围,其核心在于设计既能确保像素值位于 $[0, 1]$ 范围内,又能确保相邻像素单调性与可微性的光照增强曲线。二阶光照增强曲线可用下式表示:

$$\text{LE}(I(x); \alpha) = I(x) + \alpha I(x)(1 - I(x)) \quad (5)$$

式中, $I(x)$ 表示输入图像, x 表示像素坐标, $\text{LE}(I(x); \alpha)$ 表示映射,映射参数 $\alpha \in [-1, 1]$ 控制曲线曲率与曝光幅度。

然而,在极端暗光场景下,纯数据驱动网络在估计高维光照参数图时缺乏显式空间约束,极易导致暗部区域提亮不足或高光部分过度曝光。为解决这一问题,本文在光照曲线映射机制中创新性地引入像素光照注意力掩码,该掩码机制基于低光照图像亮度反转先验。具体而言,首先提取低光照图像单通道灰度 $I_{\text{gray}}(x)$,并通过亮度反相获取亮度特征 $M_{\text{gray}}(x)$ 。为自适应感知亮度分布,利用下式对其进行映射:

$$\begin{cases} M_{\text{gray}}(x) = 1 - I_{\text{gray}}(x) \\ M_{\text{en}}(x) = (M_{\text{gray}}(x))^{\gamma} = (1 - I_{\text{gray}}(x))^{\gamma} \end{cases} \quad (6)$$

式中, $I_{\text{gray}}(x)$ 为图像在坐标 x 处的灰度, 且已归一化至 $[0, 1]$ 区间; 参数 γ 用于控制亮度分布感知灵敏度 (本文默认设置为 $\gamma = 0.5$)。通过引入 $(1 - I_{\text{gray}})^\gamma$ 这一关键映射, 该掩码 M_{en} 被赋予明确指导意义: 对于极暗区域, 掩码响应被放大并趋近于 1; 对于高光区域, 掩码响应急剧衰减并趋近于 0。

在非线性光照曲线映射阶段, 本文摒弃了直接利用生成器输出参数驱动曲线策略, 而是将光照注意力掩码 M_{en} 与第 i 阶 RGB 三通道光照参数映射 $A_i^{\{R,G,B\}}$ 进行逐元素乘法调制。调制后的参数映射不仅包含深层网络上下文语义特征, 还融合底层光照分布先验。结合多阶迭代映射策略, 融合灰度掩码的光照曲线迭代方程可用下式表示:

$$\begin{aligned} \text{LE}_i(x) = & \text{LE}_{i-1}(x) + [A_i^{\{R,G,B\}}(x) \otimes M_{\text{en}}(x)] \\ & \cdot \text{LE}_{i-1}(x) \cdot [1 - \text{LE}_{i-1}(x)] \end{aligned} \quad (7)$$

式中, $i \in \{1, 2, \dots, n\}$ 为迭代阶数 (本文经过实验选取效果最好的迭代次数 $n=8$), $\text{LE}_0(x) = I(x)$ 表示初始输入低光照图像, $\text{LE}_i(x)$ 表示第 i 阶迭代映射后的输出图像。

3.2.4 结构保留去噪模块

在无监督低光照图像增强中, 极暗图像提亮往往引发高频噪声放大。常规全局平滑去噪在滤除噪声的同时, 极易破坏图像微观纹理, 导致增强结果呈现涂抹伪影。为此, 本文创新性地在线性光照曲线映射后, 引入一个轻量级结构保留去噪模块 (structure-preserving denoising module, SPDM), 该模块受 HINet 的半实例归一化思想启发, 进行了领域迁移与改进。由图 5 可知, 该模块主要由蓝色虚框表示的半实例归一化单元与零初始动态残差共同构成, 旨在解决“去噪必模糊”问题, 实现噪点自适应滤除与纹理结构保留。

结构保留去噪模块具体实现过程如下所述。首先, 利用 3×3 卷积获得输入图像 I_{in} 的特征映射 F_{in} ; 然后, F_{in} 依次经过 3×3 卷积与 LeakyReLU 激活, 并沿通道维度均分为特征 F_{top} 与特征 F_{bottom} : 其中对特征 F_{top} 行实例归一化, 用以消除光照偏差与局部散粒噪声; 对特征 F_{bottom} 进行恒等映射, 用以保留原始结构 (如纹理与边缘); 接着, 将纯化特征与保真特征沿通道维度重新拼接, 并经 3×3 卷积与 LeakyReLU 激活, 最后引入局部残差连接与输入特征 F_{in} 进行逐元素相加, 获得高维融合特征 F_{fused} 上述半实例归一




图5 结构保留去噪模块结构示意图。其核心部件包括: 兼顾降噪与结构保护的半实例归一化机制、保障训练稳定性的零初始动态参数调制机制, 以及用于自适应降噪的全局残差连接。

化过程可用下式表示:

$$\begin{cases} F_{\text{top}}, F_{\text{bottom}} = \text{Chunk} \left\{ \delta \left[\text{Conv}_{3 \times 3} (F_{\text{in}}) \right], 2 \right\} \\ F_{\text{fused}} = F_{\text{in}} + \delta \left\{ \text{Conv}_{3 \times 3} \left[\text{Concat}(\text{IN}(F_{\text{top}}), F_{\text{bottom}}) \right] \right\} \end{cases} \quad (8)$$

式中, δ 代表 LeakyReLU 激活函数; $\text{Chunk}(\cdot, 2)$ 表示沿通道维度将特征均分操作。

完成特征纯化后, 为确保上述空间去噪不会破坏无监督对抗训练早期稳定性, 本文在结构保留去噪模块末端创新性地引入零初始动态残差机制。高维融合特征 F_{fused} 经 3×3 降维卷积重新映射为三通道张量, 显式提取噪声残差图 R_{noise} 。最终, 通过跨越式全局残差连接, 将输入图像 I_{in} 与动态参数 ω 调制的 R_{noise} 进行逐元素相减, 得到最终增强去噪输出 I_{out} :

$$I_{\text{out}} = I_{\text{in}} - \omega \cdot R_{\text{noise}} \quad (9)$$

式中, ω 为单值可学习标量权重, 初始化阶段 $\omega = 0$ 。这一动态残差机制使得训练初期, 结构保留去噪模块输出与输入完全等价 (即 $I_{\text{out}} = I_{\text{in}}$), 从而引导参数估计生成器专注拟合宏观光照分布, 减少噪声干扰; 随着深层对抗迭代推进, ω 在反向传播梯度驱动下逐步自适应更新为非零值, 进而实现噪声消除。

3.3 全局-局部双分支判别器网络

若仅依靠生成器网络进行训练, 模型往往只能实现图像全局亮度与全局色彩恢复, 而在细节重建上存在严重不足, 导致增强结果相对模糊。为使图像更加清晰、有效保留图像结构信息, 引入判别器网络进行对抗指导至关重要。然而, 极端暗光图像往往存在光照分布极不均匀现象, 采用单一判别器难以适应这种复杂空间变化。为此, 本文引入如图 6 所示的全局-局部双分支判别器结构, 并基于 Patch-GAN 思想设计判别器网络。




图6 全局-局部双分支判别器的结构示意图,其包括两个核心部件:用于平衡宏观光照与微观纹理的全局-局部双分支、基于PatchGAN机制的生成像素真伪概率分布输出层。

由图6可知,全局判别器由五个 4×4 的卷积层构成,其中前三层采用步长为2的跨步卷积逐渐降低空间分辨率,提取深层高维语义特征;第四层采用步长为1的卷积进一步平滑特征空间;最终将图像特征映射为像素级真伪概率分布矩阵。为加速模型收敛并增强特征表征能力,本文在卷积层后引入规范化层,并利用LeakyReLU激活函数确保梯度有效传播。该全局判别器将生成器特征映射为一个 $N \times N$ 特征矩阵,有利于高质量重构全局上下文信息与局部纹理细节。

为实现微观纹理重构,本文在全局判别器架构基础上引入局部判别器。在前向传播阶段,模型每次会从生成器增强图像与正常参考图像中随机裁剪5个固定尺寸的局部图像块,并分别送入局部判别器进行鉴别。这种全局-局部协同的双分支结构,既能确保增强图像在宏观视角下的自然与和谐,又能以“放大镜”的视角有效避免局部区域过度曝光或散粒噪声扩散。

在对抗博弈策略上,为提高生成图像视觉质量并解决非配对训练过程中的不稳定缺陷,全局判别器引入相对平均判别机制。该机制在评估输入数据绝对真实性的同时,估计“真实图像比生成图像更真实”的概率,且采用最小二乘损失替换Sigmoid交叉熵函数;同样,局部判别器也采用最小二乘损失对随机裁剪图像块进行对抗约束。

3.4 多维联合约束损失

在无监督学习框架下,由于缺乏配对参考图像,必须依赖一系列精心设计约束函数引导前述的架构。本文的优化目标由对抗博弈损失与四项针对参数估计设计的先验损失共同构成,旨在驱动模型在

深层迭代中实现规律性的感知-失真动态演化。

3.4.1 全局-局部对抗损失

为使增强图像在宏观对比度与局部细节上接近真实图像,本文采用全局-局部双尺度博弈策略。

全局对抗损失:在全局尺度上,本文引入相对平均最小二乘对抗机制。该机制通过评估“真实图像是否比生成图像更真实”的相对真伪分数,为生成器提供全局一致性梯度指导。生成器全局对抗损失可用下式表示:

$$\begin{cases} L_G^{\text{Global}} = E_{\mathbf{x}_r \sim P_{\text{data}}} [(D_{R_s}(\mathbf{x}_f, \mathbf{x}_r) - 1)^2] + \\ E_{\mathbf{x}_r \sim P_{\text{real}}} [D_{R_s}(\mathbf{x}_r, \mathbf{x}_f)^2] \\ D_{R_s}(\mathbf{x}_r, \mathbf{x}_f) = C(\mathbf{x}_r) - E_{\mathbf{x}_f} [C(\mathbf{x}_f)] \end{cases} \quad (10)$$

式中, $D_{R_s}(\cdot)$ 代表相对判别输出, $C(\cdot)$ 代表全局判别器输出。

局部对抗损失:为修复微观纹理并抑制亮度增强过程中产生的噪点,本文对图像进行随机裁剪获取局部图像块,并采用最小二乘损失进行约束:

$$L_G^{\text{local}} = E_{\mathbf{x}_r \sim P_{\text{local-patches}}} [(D(\mathbf{x}_f) - 1)^2] \quad (11)$$

式中, $D(\cdot)$ 代表局部判别器输出。

因此,全局-局部双分支对抗损失为二者之和:

$$L_{\text{GAN}} = L_G^{\text{Global}} + L_G^{\text{Local}} \quad (12)$$

3.4.2 全局-局部自特征保持损失

为抑制暗光增强中常见的色偏现象,本文提出通道映射一致性损失。与传统像素色彩约束不同,该损失直接作用于生成器获得的24通道图像特征映射。假设模型进行 N 次迭代,且每次迭代的RGB通道调节参数分别为 $\alpha_R, \alpha_G, \alpha_B$,则该损失通过约束三者间的偏离度保证色彩平衡:

$$L_{\text{col}} = \sum_{i=1}^N \sum_{\Omega} \left[(\alpha_{R,i} - \alpha_{G,i})^2 + (\alpha_{G,i} - \alpha_{B,i})^2 + (\alpha_{B,i} - \alpha_{R,i})^2 \right] \quad (13)$$

式中, Ω 表示空域。当各通道参数逼近一致时,光照曲线对像素映射在数学上等效于标量缩放。因此,通道映射一致性损失有效确保增强前后图像的色彩分布比例保持恒定,从而在色度和饱和度层面实现结构保真。

3.4.3 曝光控制损失

为防止局部过曝或暗黑,本文引入曝光控制损失 L_{exp} 。该损失利用 16×16 平均池化,将增强图像局部亮度均值约束在理想曝光水平 E (本文取0.45):

$$L_{\text{exp}} = \frac{1}{M} \sum_{k=1}^M |Y_k - E| \quad (14)$$

式中, Y_k 表示增强图像在第 k 个局部区域的平均亮度值, M 表示局部块数。

3.4.4 高维参数平滑损失

为确保亮度增强过程中空间连续性并消除伪影, 本文提出高维参数平滑损失, 对光照参数空间权重调制得到的曲线参数张量实施全变分惩罚:

$$L_{TV} = \sum_{c=1}^C \sum_{w,h} (\|\nabla_x A_{c,w,h}\|^2 + \|\nabla_y A_{c,w,h}\|^2) \quad (15)$$

式中, ∇_x 和 ∇_y 分别表示水平方向和垂直方向梯度。直接平滑“曲线参数”而非“图像像素”, 能使光影过渡更加自然且不损失图像边缘细节。

3.4.5 全局-局部自特征保持损失

在非配对训练中, 生成器在极力拟合亮度分布时, 易篡改图像原始内容。为确保增强前后图像在语义内容和空间结构上保持严格一致, 本文引入基于 VGG-16 预训练网络的自特征保持损失, 该损失同样在全局-局部双分支上同时计算:

$$\begin{cases} L_{vgg}^{Global} = \frac{1}{W_i H_i C_i} \|\Phi_i(X) - \Phi_i(G(X))\|^2 \\ L_{vgg}^{local} = \sum_{p=1}^K \frac{1}{w_i h_i c_i} \|\Phi_i(X_p) - \Phi_i(g_p)\|^2 \\ L_{vgg} = L_{vgg}^{Global} + L_{vgg}^{local} \end{cases} \quad (16)$$

式中, Φ_i 表示从 ImageNet 预训练的 VGG-16 网络第 i 层提取的特征映射; X 与 $G(X)$ 分别表示原始低光照输入图像与真实光照分布图像; x_p 与 g_p 分别表示原始低光照输入图像与真实光照分布图像随机裁剪局部块; K 表示局部裁剪图像块数。

3.4.6 总体损失函数

在无监督对抗训练中, 判别器与生成器采用交替优化策略。首先, 全局与局部判别器的联合优化目标为最小化判别损失, 其计算公式如下:

$$\begin{cases} L_D^{Global} = E_{x_r \sim p_{real}} [(D_{R_s}(x_r, x_r) - 1)^2] \\ + E_{x_f \sim p_{fake}} [D_{R_s}(x_f, x_r)^2] \\ L_D^{Local} = E_{x_r \sim p_{real-patches}} [(D(x_r) - 1)^2] \\ + E_{x_f \sim p_{fake-patches}} [D(x_f)^2] \end{cases} \quad (17)$$

其次, 生成器不仅需要最小化对抗损失, 还需兼顾各项约束。综上所述, 生成器总体损失函数可用下式表示:

$$L_{total} = L_{GAN} + \lambda_{vgg} L_{vgg} + \lambda_{col} L_{col} + \lambda_{exp} L_{exp} + \lambda_{TV} L_{TV} \quad (18)$$

式中, λ_{col} 、 λ_{exp} 、 λ_{TV} 和 λ_{vgg} 分别为通道映射一致性、曝光控制、高维参数平滑、全局-局部自特征保持等各项先验损失的加权系数。这些权重系数协同调节多

维约束的相对重要性, 共同驱动模型在无监督条件下的稳定收敛。

4 实验

4.1 实验设置

4.1.1 数据集

由于本文提出的是一种非配对的无监督低光照图像增强框架, 因此在训练阶段无需严格配对的真实图像。为打破单一数据分布限制并全面验证模型综合性能, 本文实验数据配置如下。

● **混合非配对训练集**。为提升模型在真实开放场景中的泛化能力, 本文构建了一个具备高场景覆盖率的大规模混合训练集。该数据集的基础训练集整合了目前无监督低光照领域广泛使用的多场景真实图像(涵盖城市夜景、自然风光、室内弱光等公有领域数据; Jiang 等, 2021)。针对现有公开数据在极端暗光散粒噪声表征形态上相对单一的缺陷, 本文进行了数据集的深度重组与升级: 剔除冗余的基础数据, 并针对性引入 LOLv2-Real 数据集中低光照与正常光照的训练图像。这种重组策略不仅丰富了光照退化模式, 更使得模型在对抗博弈中直面真实设备产生的底噪, 从而有效激发结构保留去噪模块降噪潜能。

● **LOLv2-Real 测试集**(Liu 等, 2021)。为确保评估公正性, 本文严格采用官方划分的 LOLv2-Real 测试集作为本次实验的参考配对图像。由于 LOLv2-Real 测试集包含极暗环境下的真实图像及其严格对齐的高质量长曝光参考图, 该测试集用于定量评估模型的结构恢复能力与色彩保真能力。

● **无参考真实场景测试集**。该测试集由 LIME、DICM、MEF、NPE 及 VV 等五个广泛使用的经典非配对测试集共同构成(Guo 等, 2017; Lee 等, 2013; Ma 等, 2015; Wang 等, 2013; Vonikakis 等, 2008)。这些数据涵盖了自然风光、城市夜景、室内弱光等极其复杂真实暗光退化场景且无参考基准, 主要用于评估模型在无监督条件下的主观视觉自然度泛化性能。

4.1.2 实施细节

本文提出的无监督低光照图像增强网络基于 PyTorch2.1.2 深度学习框架与 CUDA11.8 构建。所有模型的训练与测试均在搭载 Ubuntu22.04 系统的

计算平台实现,核心硬件配置包括单张 NVIDIA GeForce RTX 4090 GPU (24GB 显存)、16 核 Intel Xeon Platinum 8352V 处理器及 120GB 运行内存。

● **超参数设置。**在模型训练阶段,为丰富数据多样性并适配模型架构,输入图像统一随机裁剪为 320×320 分辨率,每轮训练过程中批量大小设为 32。模型优化过程采用自适应矩估计(adaptive moment estimation, Adam)优化器,动量参数 β_1 和 β_2 分别设为 0.5 和 0.999。初始学习率设为 1×10^{-4} ,总训练轮次设定为 200 轮。在学习率调度上,前 100 轮迭代保持固定学习率,后 100 轮采用线性衰减策略逐步降至零。

● **多维损失权重配置。**为确保模型在无监督条件下实现感知与失真的收敛,本文对多维联合损失函数的各项系数进行严谨标定。具体而言,通道映射一致性损失系数 λ_{col} 设为 5,曝光控制损失系数 λ_{exp} 设为 10,高维参数平滑损失系数 λ_{rv} 设为 200,全局-局部自特征保持损失系数 λ_{gge} 设为 1。此外,在对抗训练中,局部判别器每次迭代随机裁剪 6 个局部图像块进行约束。

● **双版本模型提取声明。**由于模型在训练过程展现出感知-失真演化规律,本文依据独立验证集上的模型选择规则(见 4.2 节),在同一训练过程中提取两个阶段模型权重:侧重客观结构的保真模型(Ours-F)以及侧重主观视觉的感知模型(Ours-P)。

为全面评估本文模型有效性,选取 10 种具有代表性的先进低光照增强算法进行对比。其中包括传统方法 LIME(Guo 等, 2017),有监督方法 RetinexNe 与 KinD(Wei 等, 2018; Zhang 等, 2019),无监督方法 EnlightenGAN、Zero-DCE、SCI、CoLIE、CLODE、DNet(Jiang 等, 2021; Guo 等, 2020; Ma 等, 2022; Chobola 等, 2024; Jung 等, 2025; Li 等, 2025),以及 2026 年最新开源的轻量级方法 SPJFNet(Zhang 等, 2026)。受限于论文版面,定性视觉对比结果仅挑选各场景下最具代表性的部分算法进行可视化展示,而完整的全量算法对比结果则详见定量评价表格。

4.1.3 评价指标

为从客观结构保真度与主观视觉感知度两个维度全面量化模型增强性能,本文针对不同类型的测试集,分别采用了全参考与无参考两类图像质量评价指标。

● **无参考评价指标。**针对缺乏参考基准的极其

复杂的真实开放场景测试集(DICM、LIME、MEF、NPE 以及 VV),本文选用自然图像质量评价指标(natural image quality evaluator, NIQE; Mittal 等, 2013)。NIQE 通过提取自然图像统计特征构建空间域的多元高斯模型,有效量化增强图像在对比度异常、色彩偏移、重度噪声伪影等方面的主观感知退化程度。NIQE 值越小,表明增强图像视觉效果越自然、越符合人眼主观感知。

● **全参考评价指标。**针对具备真实配对测试集(LOLv2-Real),本文选用峰值信噪比(peak signal-to-noise ratio, PSNR)、结构相似度(structural similarity, SSIM; Wang 等, 2004)、学习感知图像块相似度(learned perceptual image patch similarity, LPIPS; Zhang 等, 2018)作为定量评价指标,其中的 PSNR 基于像素间均方误差衡量增强图像全局像素级失真程度;SSIM 从亮度、对比度和纹理结构三个维度评估重构图像纹理一致性;而 LPIPS 则依托深度特征,从更贴近人类视觉系统的感知维度衡量图像间的差异。具体而言,PSNR 与 SSIM 值越大,表明模型客观结构保真能力越强;而 LPIPS 值越小,则代表增强图像的感知质量越接近真实的高质量参考图。

4.2 验证集演化分析与模型选择

本文在训练阶段构建了独立的验证集,在多组随机种子的独立训练下,模型在验证集上的定量指标随迭代轮次(Epochs)的变化曲线如图 7 所示。

观察曲线可以发现,模型训练呈现出规律的“感知-失真”动态演化特征:在训练早中期,受特征自保持与高维参数平滑等先验损失的约束,模型的 PSNR、SSIM 迅速攀升至峰值,且 LPIPS 降至极小值,表明此时模型侧重于图像的客观结构保真度;而随着训练推移至后期,在全局-局部双分支对抗损失的约束 NIQE 指标稳步下降并达到全局最优,表明此时模型生成的光影与细节最符合人类的主观视觉自然度。

基于上述独立验证集上揭示规律,每次训练据此提取两个检查点用于后续测试:提取早中期结构指标最优时(基于验证集结果选取三个指标综合最好)的权重作为保真模型(Ours-F),提取后期自然度指标最优时的权重作为感知模型(Ours-P)。在后续对比实验中,本文将同时报告双操作点在全量指标下的表现。




图7 模型在独立验证集下各项指标的变化曲线。从左到右依次为NIQE、PSNR、SSIM和LPIPS,五角星处为最优值。




图8 在包含极端动态范围与复杂纹理的真实低光场景下,不同增强算法的主观视觉对比与局部细节放大分析。为突显局部纹理保真与色彩还原差异,关键特征区域已用红色与黄色边框标出并在原图下方单独放大展示。

4.3 定性视觉对比

为直观且全面验证本文方法在不同光照条件下的增强性能与泛化性能,本节分别在无参考的真实开放场景与全参考的真实标签场景下进行主观视觉分析。

4.3.1 无参考真实场景定性分析

本节选取具有代表性的真实极端无参考低光场景进行评估,涵盖图8(a)复杂纹理的自然景观、图8(b)色彩渐变的黄昏景观及图8(c)动态逆光人像。实验结果表明,基于传统物理模型的LIME方法虽显著提升整体亮度,但因缺乏全局曝光维度的自适应约束,在强光源或亮区极易局部过曝,导致高光细节完全丢失(如第三行黄色与红色放大区域中,窗外景色与面部高光严重泛白)。

在深度学习方法中,零参考无监督模型Zero-DCE计算效率极高,在亮度提升与自然度保真间取得良好平衡。但因其浅层网络未显式引入空域降噪约束,大幅增强极暗区域时不可避免地放大了底层高频散粒噪声。同属无监督的SCI模型在逆光场景(第三行)的高光抑制与暗部平滑能力亦显不足。无

监督方法CoLIE在真实极端暗光下亮度提升明显不足(如第一行植被与第三行逆光人像放大框),未能有效恢复暗部细节。此外,频域解耦网络DEnet整体结构保真出色,但在处理极端色彩渐变(第二行天空)时自然度仍待优化。轻量级SPJFNet虽显著提升光照,但受限于跨域泛化瓶颈,处理复杂场景时出现严重的高频结构丢失与过度平滑(如第一行悬崖纹理被彻底涂抹),且强光源区伴有生硬局部过曝(如第二行灯塔背景)。

相比之下,本文的晚期感知模型(Ours-P)展现出优异的视觉感知与结构保真度。这主要得益于本文框架:编码阶段,多尺度特征提取与抗噪卷积注意力实现全局光照感知与抗噪;后端非线性映射后,基于半实例归一化的结构保留去噪模块自适应剥离噪声。这种贯穿特征与图像域的级联降噪,有效缓解了无监督网络中“亮度提升”与“过度平滑”的固有矛盾。同时,在通道一致性与曝光控制损失约束下,Ours-P有效抑制了高光过曝风险。如图7放大区域所示,无论是悬崖砖块纹理、天空自然渐变,还是逆光人像细节,Ours-P均实现了更为自然精细的还原,

在降噪、亮度恢复与色彩保真间取得良好平衡。

4.3.2 全参考标准场景定性分析

为进一步验证模型在标准参考基准下结构恢复精度与色彩还原能力,本文选取 LOLv2-Real 配对数据集中室内场景与大空间场景进行实验。该测试集具备真实环境下的长曝光参考真值图,能为客观保真度提供极其严格的性能评价指标。

由图9所示实验结果可知,不同方法在全参考场景下呈现显著视觉差异。有监督方法 KinD 虽有效提升图像整体可见度,但在光照分布均匀性与色彩饱和度上略显不足,画面整体偏暗(如第一行沙发区域的光影过渡不自然)。作为无监督生成对抗框架代表,EnlightenGAN 方法虽大幅拉伸亮度,但在深层非线性映射过程中出现明显的色彩失真与语义偏差(如第二行室内泳池的水面与池底被错误映射为异常的绿色)。无监督方法 CLODE 虽能显著提亮画面,但暴露出严重的色偏问题,其重构的色彩分布与参考真值图存在巨大偏差。此外,基于频域解耦的无监督方法 DEnet 在纹理结构恢复上表现优异,但

在处理大面积同色系区域时,其整体画面呈现出轻微灰白雾感(如第三行体育馆的整体色调发灰),色彩鲜艳度未能完全贴合真实场景。作为 2026 年最新开源的轻量级方法,SPJFNet 虽在全局光照提升上表现稳定,但在参考场景下暴露出严重的色彩饱和度缺失与对比度退化问题,如图8第三、四行所示,其重建的体育馆蓝色座椅呈现出明显的灰暗褪色现象,导致图像整体观感发白。

相比之下,本文保真模型(Ours-F)在所有对比基线中展现出最佳重构精度。得益于全局-局部自特征保持损失的约束与特征域的有效降噪,Ours-F 不仅在微观结构细节实现有效保真,更在极具挑战的色彩还原上表现优异。如图9第三、四行所示,面对体育馆内复杂的环境光与大面积的蓝色座椅,Ours-F 极其精准地还原了体育馆的深蓝色泽与真实的光影层次,其主观视觉感官与真实图像间展现出极高的一致性。这一结果充分证明本文所提框架在应对严格配对重构任务时,能够有效抵御色彩漂移与噪声干扰,实现高度结构保真的图像增强。




图9 在具备真实标签的 LOLv2-Real 全参考配对数据集下,不同增强算法的主观视觉对比分析。为突显各模型在结构重构与色彩还原上的客观差异,最右侧列补充了真实环境下的长曝光参考真值图(GT)以供严格对标。

4.4 定量评价

为从客观数据层面全面验证本文方法的增强性能,本节采用包括峰值信噪比、结构相似度、学习感知图像块相似度在内的自然图像质量评价指标对无参考真实场景下的图像增强效果进行量化评估。

4.4.1 无参考真实场景定量分析

为客观评估模型在无参考图像下的泛化能力与视觉自然度,本文在 DICM 等 5 个真实数据集上测试了 NIQE 指标(见表1,越低代表图像越自然)。

实验表明,极端暗光下强行提亮易引入色偏与伪影,导致自然度退化:1) RetinexNet、KinD、DEnet 及 SPJFNet,其自然度在多数数据集上甚至劣于原图。2) 在 VV 数据集上,多数包含复杂特征重构的深度网络退化尤为显著。3) 尽管 Zero-DCE、CoLIE 和 CLODE 平均 NIQE 较低,但这主要因为 NIQE 对“平滑”惩罚不足,导致平滑图像得分虚低。

相比之下,本文 Ours-P 模型展现了较好的综合性能与视觉自然度,较小的标准差证明了其对随机

初始化的鲁棒性。得益于特征域净化与空间域去噪的协同及多维损失引导,Ours-P在去噪与恢复纹理的同时,有效避免“以平滑换取指标”,在主观感知与客观评估间取得了稳健平衡。

表1 不同方法在五个真实无参考数据集上的 NIQE 评估结果(越低越好)。

Method	DICM	LIME	MEF	NPE	VV	Average		
Input	4.254	4.351	4.266	4.324	3.524	4.126		
LIME	3.744	3.944	3.316	4.439	4.768	3.944		
RetinexNet	4.263	5.487	4.253	4.321	6.235	4.752		
KinD	4.293	4.537	4.136	4.486	5.972	4.631		
EnlightenGAN	<u>3.583</u>	3.692	<u>3.317</u>	4.062	3.932	3.654		
Zero-DCE	3.731	<u>3.771</u>	<u>3.283</u>	3.946	2.626	3.471		
SCI	4.148	4.451	3.633	4.453	5.885	4.463		
CoLIE	3.789	3.973	3.425	4.104	2.954	3.611		
CLODE	3.738	4.007	3.639	3.946	<u>2.901</u>	<u>3.596</u>		
DENet	4.493	4.681	4.273	4.275	6.235	4.813		
SPJFNet	5.258	5.283	5.709	5.548	5.479	5.384		
Ours-F	3.7307 ± 0.1418	3.9747 ± 0.1022	3.4630 ± 0.2423	4.1296 ± 0.1516	4.4118 ± 0.2476	3.8724 ± 0.1677		
Ours-P	3.5591	0.0152	3.8092 ± 0.1418	3.1914	0.0506	<u>3.9948 ± 0.0869</u>	4.0135 ± 0.0861	3.6456 ± 0.0350

注:加粗表示最优数据,下划线表示次优数据。

4.4.2 全参考标准场景定量分析

为进一步评估模型在面对全参考标准时的精度,本文在LOLv2-Real数据集上进行全参考指标评测。该测试采用峰值信噪比(PSNR)、结构相似度(SSIM)以及学习感知图像块相似度(LPIPS)三个核心评价指标,其中峰值信噪比与结构相似度值越高,表明增强结果在像素级保真度与结构完整性越接近参考真实图;学习感知图像块相似度值越低,表明增强结果越符合人类自然视觉感知。具体定量实验对比结果如表2所示。

需要特别说明的是,RetinexNet与KinD属于完全有监督模型(表2中以*标注),其在训练阶段直接利用配对参考真实图计算L1/L2与SSIM损失。这种强约束机制使其在全参考评测中具有天然指标优势(例如KinD取得0.869的SSIM与0.142的LPIPS)。然而,结合表1及对应的视觉定性分析可知,单纯依赖像素级强监督极易导致模型在真实复杂场景中陷入过拟合,产生严重的色彩失真与自然度退化。因此,本文将作为性能参考基线,重点关注无监督模型间的性能对比。

由表2所示实验结果可知以下结论。1) 在无参

表2 不同模型在LOLv2-Real数据集的全参考性能对比。

Method	PSNR/dB	SSIM	LPIPS
LIME	17.141	0.641	0.342
RetinexNet*	<u>17.715</u>	0.679	0.439
KinD*	20.894	0.869	0.142
EnlightenGAN	17.879	0.703	0.297
Zero-DCE	18.059	0.677	0.313
SCI	17.304	0.629	0.308
CoLIE	15.070	0.586	0.322
CLODE	17.634	0.718	0.348
DEnet	20.348	0.829	<u>0.266</u>
SPJFNet	<u>21.282</u>	0.805	0.364
Ours-P	19.7483	0.7425	0.2779
Ours-F	21.4853	<u>0.8083</u>	0.2331

注:标有*的方法为有监督学习模型。由于其在训练阶段直接使用配对参考真实图进行像素级强约束,因此在全参考指标上具有天然优势,此处仅作为性能上限参考基线,不参与无监督方法性能对比;在此基础上,加粗表示最优数据,下划线表示次优数据。

考真实场景性能对比中,传统模型 LIME 与极简曲线映射模型 Zero-DCE、SCI 虽有一定自然度优势,但由于缺乏底层微观特征重构能力,其峰值信噪比与结构相似度偏低,无法实现结构和纹理还原。2) CoLIE 与 CLODE 的输出图片往往过于平滑,不利于纹理结构保真,因此的整体表现相对受限,各项指标均处于劣势。相比之下,作为基于频域解耦的最新代表模型,DEnet 展现出较好的综合性能,实现结构恢复与视觉感知的良好平衡。3) 虽然 SPJFNet 模型取得次优的峰值信噪比 (21.282dB),甚至超越部分有监督基线,但其学习感知图像块相似度得分 (0.3642) 却相对偏高。这印证了前文定性分析中的“灰暗褪色与白雾感”问题,表明该算法陷入像素级均方差过拟合,以牺牲真实色彩与视觉自然感知为代价换取虚高性能指标。

相比之下,本文提出的保真模型 Ours-F 展现出卓越综合性能,在客观结构保真度与视觉感知质量上实现突破。得益于结构保留去噪模块对噪声的有效剥离,及多维联合约束损失的全局引导,Ours-F 不仅取得了无监督方法中最优的峰值信噪比,其在学习感知图像块相似度与结构相似度上也表现优异,多次独立实验中较小的标准差波动也进一步证明了本文方法的稳健性。此外,Ours-F 在未依赖成对真值进行像素级强约束的前提下,其 PSNR 指标不仅超越了有监督基线 KinD,更有效克服了如 SPJFNet 等方法中客观指标与实际感知质量割裂的局限性。这充分证明,Ours-F 能够在重建纹理结构的同时,实现了客观结构保真与主观视觉自然的协同提升。

4.5 消融实验

为验证本文所提模型中各个核心组件及联合损失函数有效性,本节在 LOLv2-Real 数据集上进行消融实验,并采用 PSNR、SSIM 和 LPIPS 作为客观评价指标。

4.5.1 网络结构消融实验

为验证本文所提模型中各核心组件有效性,在 LOLv2-Real 数据集上对各个模块进行消融测试。实验以去除了所有创新模块的基础生成网络 (ModelA) 为基线,并逐步叠加多尺度特征提取模块 (MSFEM, 对应 ModelB)、抗噪卷积注意力模块 (NRCBAM, 对应 ModelC) 以及结构保留去噪模块 (SPDM, 对应保真模型 Ours-F)。消融实验结果如表 3 所示。

由表 3 所示实验结果可知本文各模块对图像重构质量的协同作用。1) 基础网络 ModelA 的保真度较低 (PSNR 仅为 18.207dB),这说明常规卷积堆叠难以应对复杂暗光退化。2) 引入多尺度特征提取模块后 (ModelB),模型能够有效捕捉更丰富的多尺度空间特征,PSNR 提升了 0.699dB。3) 叠加抗噪卷积注意力模块 (ModelC) 后,得益于注意力机制对关键通道与空间位置的精准聚焦,PSNR 再次提升了 0.843dB,同时 LPIPS 也得到显著改善。4) 进一步引入 SPDM 模块后,性能得以显著提升。Ours-F 的 PSNR 实现了 1.699dB 的大幅跨越,达到 21.485dB,且 SSIM 突破 0.8。这一结果强有力地证明了在应对真实暗光场景时,仅依靠多尺度特征提取与抗噪卷积注意力是不够的;本文设计的结构保留去噪模块通过在空间域进行截断去噪,是模型实现客观结构保真度的重要保证。

表 3 本文所提模块在 LOLv2-Real 数据集的消融实验。
(注: Ours-F 采用多次独立训练的均值展示)

变体	MSFEM	NRCBAM	SPDM	PSNR/ dB	SSIM	LPIPS
Model A				18.207	0.684	0.332
Model B	✓			18.906	0.693	0.315
Model C	✓	✓		19.749	0.722	0.305
Ours-F	✓	✓	✓	21.485	0.808	0.233

注:加粗表示最优数据。

4.5.2 损失函数消融实验

表 4 本文所提损失函数在 LOLv2-Real 数据集的消融实验。(注: Ours-F 采用多次独立训练的均值展示)

Method	PSNR/dB	SSIM	LPIPS
$L_{GAN} + L_{vgg}$	18.89	0.726	0.272
$L_{GAN} + L_{vgg} + L_{exp}$	21.126	0.784	0.26
$L_{GAN} + L_{vgg} + L_{exp} + L_{col}$	21.245	0.792	0.251
Ours-F	21.485	0.808	0.233

注:加粗表示最优数据。

为验证本文所设计的联合损失函数中各项约束损失的必要性,本节在 LOLv2-Real 数据集上进行了递进式消融测试。如表 4 所示,基础模型仅保留了全局-局部对抗损失与全局-局部自特征保持损失。尽管基础网络能够实现画面整体亮度增强,但由于

缺乏对像素级亮度直接约束,模型在极端暗光下易导致局部区域过曝或欠曝,其PSNR仅为18.890dB。

在引入曝光控制损失后,图像整体亮度被强制锚定在正常光照分布区间内,有效解决了过曝与欠曝问题。这一约束损失使得模型客观评价指标得以显著提升,PSNR提升至21.126dB。然而,由于此时尚未引入色彩约束,暗部区域在大幅亮度增强后,极易导致由底层噪声引发的紫斑、绿块等严重色偏现象。

为此,叠加通道映射一致性损失。该损失有效纠正了通道间不平衡,有效消除图像中的紫斑与色偏,颜色恢复至自然状态,SSIM进一步提升至0.792,LPIPS也显著下降。

最后,针对高维曲线映射在局部空间可能引发的生硬伪影、光晕及色块断层问题,本文保真模型(Ours-F)引入高维参数平滑损失。作为极其关键的空间约束,其促使模型在保持边缘锐度的同时,实现平坦区域极其平滑的光影过渡。最终完整模型的PSNR(21.485dB)与SSIM(0.808)均达到最优状态,实现客观结构保真与主观视觉自然的统一,证明本文所提模型的有效性。

4.5.3 超参数消融实验

为验证模型中核心超参数设置的合理性,本文针对亮度分布感知灵敏度 γ 、光照曲线迭代阶数 n 以及半实例归一化比例进行了敏感性消融实验,结果如表5所示。

表5 核心超参数在LOLv2-Real数据集的消融实验。(注:Ours-F采用多次独立训练的均值展示)

超参数	设置	PSNR/ dB	SSIM	LPIPS
亮度分布感知灵敏度 γ	$\gamma=0.3$	21.177	0.779	0.260
	$\gamma=0.7$	21.296	0.774	0.263
光照曲线迭代阶数 n	$n=2$	19.524	0.695	0.325
	$n=4$	20.352	0.784	0.275
	$n=16$	21.040	0.762	0.295
半实例归一化比例	0.25	20.872	0.795	0.251
	0.75	21.134	0.782	0.264
-	Ours-F	21.485	0.808	0.233

注:加粗表示最优数据。

实验表明,当亮度分布感知灵敏度 γ 偏离默认值时,模型对全局光照的映射能力下降,导致亮暗区域的亮度调节失衡,各项客观指标均呈现不同程度的衰减。对于光照曲线迭代阶数 n ,该参数决定了非线性增强曲线的拟合自由度:当 n 取值较小时,低阶映射曲线的表达空间有限,难以提供充足曲度来恢复极端暗光区域,导致暗部细节增强不足,PSNR指标偏低;而当 n 取值过大时,冗余的迭代自由度使得曲线过于敏感,易诱发局部色彩失真与伪影,导致SSIM下降且LPIPS指标变差。此外,半实例归一化比例控制特征空间中去噪与细节保留的平衡:比例过低会导致噪声残留而降低PSNR;比例过高则引发过度平滑,造成纹理丢失,使得SSIM降低。综合实验结果验证了本文Ours-F所采用的基线配置($\gamma=0.5, n=8$,半实例归一化比例=0.5)能够在亮度提升、噪声抑制与细节保留之间达到平衡。

5 总 结

本文针对低光照图像增强任务中缺乏先验约束导致细节丢失与色彩失真,及提亮易引发噪声放大等问题,提出一种基于光照曲线映射与结构保留去噪的无监督低光照图像增强方法。

在生成阶段,本文提出融合亮度反转先验的非线性光照曲线迭代映射机制,旨在解决细节增强与色彩失真问题。为保障曲线映射所需参数的精准估计,本文设计多尺度特征提取模块与抗噪卷积注意力模块,有效解决极暗场景下全局光照感知受限与噪声干扰参数估计问题。针对提亮引发噪声放大问题,本文提出结构保留去噪模块,设计零初始动态残差的半实例归一化机制,在不破坏无监督对抗训练稳定性的前提下,保留图像真实纹理,有效滤除放大噪点。

在判别与优化阶段,通过引入通道映射一致性、曝光控制、高维参数平滑等多维联合约束损失,引导模型训练呈现规律性感知-失真演化特征,并提取侧重客观结构保真度与主观视觉自然度的双阶段模型。实验结果表明,在全参考LOLv2-Real数据集上,保真模型Ours-F在PSNR、SSIM和LPIPS指标上均表现优异,PSNR达到21.485dB,超越了部分全监督基线模型;在无参考真实场景测试中,感知模型

Ours-P 取得了 3.646 的平均 NIQE 值。以上结果表明, 本方法能够有效消除色偏与涂抹伪影, 同时高效还原场景光影与真实结构。

尽管本文方法在降噪与亮度增强上取得显著成效, 但双分支判别器与多尺度注意力等机制的引入一定程度上增加了模型计算复杂度, 因此未来研究工作将聚焦于模型轻量化, 以期在端侧移动设备上实现实时推理; 此外, 探索光照曲线映射与结构保留去噪框架在低光照视频增强等动态时序任务中的泛化应用, 也是进一步挖掘其底层视觉潜力的重要方向。

参考文献

- Blau Y and Michaeli T. 2018. The perception-distortion tradeoff//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE: 6228-6237 [DOI: 10.1109/CVPR.2018.00652]
- Chen C, Chen Q F, Xu J and Koltun V. 2018. Learning to see in the dark//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE: 3291-3300 [DOI: 10.1109/CVPR.2018.00347]
- Chen L Y, Lu X, Zhang J, Chu X J and Chen C P. 2021. HINet: half instance normalization network for image restoration//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE: 182-192 [DOI: 10.1109/CVPRW53098.2021.00027]
- Chobola T, Liu Y, Zhang H Y, Schnabel J A and Peng T Y. 2024. Fast context-based low-light image enhancement via neural implicit representations//Proceedings of the European Conference on Computer Vision. Milan: Springer: 413-430 [DOI: 10.1007/978-3-031-73016-0_24]
- Du S L, Dang H, Zhao M H and Shi Z H. 2023. Low-light image enhancement and denoising with internal and external priors. *Journal of Image and Graphics*, 28(9): 2844-2855 (都双丽, 党慧, 赵明华, 石争浩. 2023. 结合内外先验知识的低照度图像增强与去噪算法. *中国图象图形学报*, 28(9): 2844-2855) [DOI: 10.11834/jig.220707]
- Guo C L, Li C Y, Guo J C, Loy C C, Hou J H, Kwong S, et al. 2020. Zero-reference deep curve estimation for low-light image enhancement//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE: 1777-1786 [DOI: 10.1109/CVPR42600.2020.00185]
- Guo X J, Li Y and Ling H B. 2017. LIME: low-light image enhancement via illumination map estimation. *IEEE Transactions on Image Processing*, 26(2): 982-993 [DOI: 10.1109/TIP.2016.2639450]
- Jia Y F, Yu W S, Chen G D and Zhao L Q. 2024. Nighttime road scene image enhancement based on cycle-consistent generative adversarial network. *Scientific Reports*, 14(1): 14375 [DOI: 10.1038/s41598-024-65270-3]
- Jiang Y F, Gong X Y, Liu D, Cheng Y, Fang C and Shen X H. 2021. EnlightenGAN: deep light enhancement without paired supervision. *IEEE Transactions on Image Processing*, 30: 2340-2349 [DOI: 10.1109/TIP.2021.3051462]
- Jobson D J, Rahman Z and Woodell G A. 1997. A multiscale retinex for bridging the gap between color images and the human observation of scenes. *IEEE Transactions on Image Processing*, 6(7): 965-976 [DOI: 10.1109/83.597272]
- Jung D, Kim D and Kim T H. 2025. Continuous exposure learning for low-light image enhancement using neural ODEs//Proceedings of the International Conference on Learning Representations.
- Land E H. 1977. The retinex theory of color vision. *Scientific American*, 237(6): 108-128 [DOI: 10.1038/scientificamerican1277-108]
- Lee C, Lee C and Kim C. 2013. Contrast enhancement based on layered difference representation of 2D histograms. *IEEE Transactions on Image Processing*, 22(12): 5372-5384 [DOI: 10.1109/TIP.2013.2284059]
- Li C Y, Guo C L, Han L H, Jiang J, Cheng M M and Gu J W. 2021. Low-light image and video enhancement using deep learning: a survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 44(12): 9396-9416 [DOI: 10.1109/TPAMI.2021.3126387]
- Li H Q, Hu X W and Wang H Q. 2025. Interpretable unsupervised joint denoising and enhancement for real-world low-light scenarios//Proceedings of the International Conference on Learning Representations. [DOI: 10.48550/arXiv.2503.14535]
- Li X, Wang W H, Hu X L and Yang J. 2019. Selective kernel networks//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE: 510-519 [DOI: 10.1109/CVPR.2019.00060]
- Liu J Y, Xu D J, Yang W H, Fan M H and Huang H F. 2021. Benchmarking low-light image enhancement and beyond. *International Journal of Computer Vision*, 129(4): 1153-1184 [DOI: 10.1007/s11263-020-01418-8]
- Lore K G, Akintayo A and Sarkar S. 2017. LLNet: a deep autoencoder approach to natural low-light image enhancement. *Pattern Recognition*, 61: 650-662 [DOI: 10.1016/j.patcog.2016.06.008]
- Lv Z W, Niu H J, Sun F Y and Zhen T. 2025. Review of low-light image enhancement algorithms. *Infrared Technology*, 47(2): 165-178 (吕宗旺, 牛贺杰, 孙福艳, 甄彤. 2025. 低光照图像增强算法研究综述. *红外技术*, 47(2): 165-178)
- Ma K, Zeng K and Wang Z. 2015. Perceptual quality assessment for multi-exposure image fusion. *IEEE Transactions on Image Processing*, 24(11): 3345-3356 [DOI: 10.1109/TIP.2015.2442920]
- Ma L, Ma T Y, Liu R S, Fan X and Luo Z X. 2022. Toward fast, flexible, and robust low-light image enhancement//Proceedings of the

- IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans: IEEE: 5627-5636 [DOI: 10.1109/CVPR52688.2022.00555]
- Mittal A, Soundararajan R and Bovik A C. 2013. Making a "completely blind" image quality analyzer. *IEEE Signal Processing Letters*, 20(3): 209-212 [DOI: 10.1109/LSP.2012.2227726]
- Pizer S M, Amburn E P, Austin J D, Cromartie R, Geselowitz A, Greer T, et al. 1987. Adaptive histogram equalization and its variations. *Computer Vision, Graphics, and Image Processing*, 39(3): 355-368 [DOI: 10.1016/S0734-189X(87)80186-X]
- Tian Z, Qu P X, Li J L, Sun Y K, Li G H, Liang Z, et al. 2023. A survey of deep learning-based low-light image enhancement. *Sensors*, 23(18): 7763 [DOI: 10.3390/s23187763]
- Vonikakis V, Andreadis I and Gasteratos A. 2008. Fast center-surround contrast modification. *IET Image Processing*, 2(1): 19-34 [DOI: 10.1049/iet-ipr:20070012]
- Wang B Y and Hoai M. 2018. Back to the beginning: starting point detection for early recognition of ongoing human actions. *Computer Vision and Image Understanding*, 175: 24-31 [DOI: 10.1016/j.cviu.2018.10.001]
- Wang L T, Zhao L Q, Zhong T and Wu C M. 2024. Low-light image enhancement using generative adversarial networks. *Scientific Reports*, 14(1): 18489 [DOI: 10.1038/s41598-024-69505-1]
- Wang S H, Zheng J, Hu H M and Li B. 2013. Naturalness preserved enhancement algorithm for non-uniform illumination images. *IEEE Transactions on Image Processing*, 22(9): 3538-3548 [DOI: 10.1109/TIP.2013.2261309]
- Wang W C, Wu X J, Yuan X H and Gao Z R. 2020. An experiment-based review of low-light image enhancement methods. *IEEE Access*, 8: 87884-87917 [DOI: 10.1109/ACCESS.2020.2992749]
- Wang Z, Bovik A C, Sheikh H R and Simoncelli E P. 2004. Image quality assessment: from error visibility to structural similarity. *IEEE Transactions on Image Processing*, 13(4): 600-612 [DOI: 10.1109/TIP.2003.819861]
- Wei C, Wang W J, Yang W H and Liu J Y. 2018. Deep retinex decomposition for low-light enhancement. *arXiv preprint arXiv: 1808.04560* [DOI: 10.48550/arXiv.1808.04560]
- Woo S, Park J, Lee J and Kweon I S. 2018. CBAM: convolutional block attention module//*Proceedings of the European Conference on Computer Vision*. Munich: Springer: 3-19 [DOI: 10.1007/978-3-030-01234-2_1]
- Zhang R, Isola P, Efros A A, Shechtman E and Wang O. 2018. The unreasonable effectiveness of deep features as a perceptual metric//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*: 586-595 [DOI: 10.1109/CVPR.2018.00068]
- Zhang T S, Liu P L, Zhang Z J and Zhou Q Z. 2026. SPJFNet: self-mining prior-guided joint frequency enhancement for ultra-efficient dark image restoration//*Proceedings of the AAAI Conference on Artificial Intelligence* [DOI: 10.1609/aaai.v40i15.38277]
- Zhang Y H, Zhang J W and Guo X J. 2019. Kindling the darkness: a practical low-light image enhancer//*Proceedings of the ACM International Conference on Multimedia*. New York: ACM: 1632-1640 [DOI: 10.1145/3343031.3350926]
- Zhao M H, Wen Y C, Du S L, Hu J, Shi C and Li P. 2024. Low-light image enhancement algorithm based on illumination and scene texture attention map. *Journal of Image and Graphics*, 29(4): 862-874 (赵明华, 汶怡春, 都双丽, 胡静, 石程, 李鹏. 2024. 基于照度与场景纹理注意力图的低光图像增强. *中国图象图形学报*, 29(4): 862-874) [DOI: 10.11834/jig.230271]
- Zuiderveld K. 1994. Contrast limited adaptive histogram equalization//*Heckbert P S. Graphics Gems*. San Diego: Academic Press: 474-485 [DOI: 10.1016/B978-0-12-336156-1.50061-6]

作者简介

邵天翔,男,本科生,主要研究领域为深度学习、图像处理。
E-mail:1729511303@qq.com

朱松豪,男,博士,副教授,主要研究领域为图像处理、人工智能。
E-mail:zhush@njupt.edu.cn

刘佳伟,男,硕士,工程师,研究方向为图像处理、网络通信。
E-mail:342147078@qq.com