



· 深度学习视觉处理与分析 ·

【主持人语】随着人工智能与深度学习技术的快速发展,图像处理相关研究正不断向智能化、高精度和多场景应用方向迈进,并在遥感监测、智能安防、低照度视觉感知以及高光谱成像等领域展现出广阔的应用前景。作为计算机视觉领域的重要研究方向,图像增强、图像重建、场景解析与目标感知等关键技术近年来取得了显著进展,为复杂环境下视觉信息的高效获取与理解提供了重要支撑。本专题聚焦深度学习在图像处理领域的前沿应用研究,共收录4篇研究论文,内容涵盖低照度图像增强、高光谱图像超分辨率重建、遥感图像道路提取以及密集场景人群计数等方向。其中:《光照先验引导的低照度图像增强方法》针对现有方法存在光照适应性差、全局结构与局部细节难以平衡的问题,提出一种光照先验引导的低照度图像增强方法,在光照校正、噪声抑制和细节保持等方面展现出显著优势;《基于双域聚合 Transformer 的高光谱图像超分辨率重建方法》通过构建双域空间-光谱聚合 Transformer 网络,实现了空间与光谱信息的联合建模,显著提升了单高光谱图像超分辨率重建质量;《结合注意力与自适应特征融合的遥感图像道路提取》以 VGG16 为骨干网络,在 Unet 网络跳跃连接处加入跨空间多尺度注意力模块,有效融合全局上下文信息,提升了对复杂背景和遮挡区域的特征感知能力;《深度频谱自适应调制的密集场景人群计数方法》针对密集场景下人群尺度变化剧烈、遮挡严重以及透视畸变的问题,提出一种基于深度频谱自适应调制的人群计数算法,通过深度感知模块实现多尺度特征提取与透视校正,取得了优异的人群计数性能。期待本专题能够为图像增强、场景理解与高维视觉重建等方向的研究提供有益参考,进一步推动深度学习方法在复杂视觉场景中的理论研究与实际应用。同时,也希望相关研究成果能够为人工智能与图像处理交叉领域的发展带来新的思路与启发。

【主持人】张凯兵,西安工程大学计算机科学学院教授。

光照先验引导的低照度图像增强方法

张凯兵^{1,2},任可心¹,李英健¹,孟雅蕾¹,李鹏芳¹

1. 西安工程大学 计算机科学学院, 陕西 西安 710048; 2. 陕西省服装设计智能化重点实验室, 陕西 西安 710048

摘要 针对现有低照度图像增强方法存在光照适应性差、全局结构与局部细节难以平衡的问题,提出一种光照先验引导的低照度图像增强方法(light-prior driven low-light enhancement network, LPD-Net)。首先,基于 Retinex 理论构建光照先验估计模块(illumination prior module, IPM),通过引入同态滤波先验生成光照归一化特征,实现对非均匀光照的全局校正。其次,构建基于编码器解码器架构的 Mamba 优化增强模块(Mamba enhanced module, MEM),采用分层建模策略,构建由局部窗口 Mamba 与全局 Mamba 组成的多尺度路径,实现局部细节增强与全局亮度恢复。在此基础上,引入双流融合色彩调制模块(dual-stream fusioncolor modulation, DFCM),通过双向卷积块获取横纵空间依赖关

收稿日期:2025-12-26 修回日期:2026-01-08

基金项目:国家自然科学基金(61971339);陕西省重点产业创新链项目(2024GX-ZDCYL-02-07)。

第一作者:张凯兵,男,博士,教授,博士生导师,从事机器学习、图像超分辨重建等研究,zhangkaibing@xpu.edu.cn。

系,并结合轻量注意力机制实现全局局部特征的融合。同时,利用通道门控与色彩调制机制自适应恢复色彩信息与局部图像细节。最后,通过引入总变差正则化对光照图进行约束,防止因过度增强而导致的图像结构一致性问题。实验结果表明,本文方法在 LOLv1 数据集上取得了 24.370 dB 的 PSNR 与 0.853 的 SSIM,性能明显优于现有方法。该方法在光照校正、噪声抑制和细节保持等方面均展现出显著优势,同时对实际低照度场景也具有良好的泛化能力。

关键词 低照度图像增强;状态空间;同态滤波;色彩调制模块;总变差正则
中图分类号:TP391.41 **DOI**:10.16152/j.cnki.xdxbr.2026-03-007

Illumination prior guided low-light image enhancement method

ZHANG Kaibing^{1,2}, REN Kexin¹, LI Yingjian¹, MENG Yalei¹, LI Pengfang¹

1. School of Computer Science, Xi'an Polytechnic University, Xi'an 710048, China;
2. Shaanxi Key Laboratory of Clothing Intelligence, Xi'an 710048, China

Abstract Aiming at the shortcomings of existing low-light image enhancement methods, such as poor illumination adaptability and difficulty in balancing global structure and local details, this paper proposes a light-prior driven low-light enhancement network (LPD-Net). First, an illumination prior module (IPM) is constructed based on Retinex theory, which generates illumination-normalized features by introducing homomorphic filtering priors to achieve global correction of non-uniform illumination. Second, a Mamba enhanced module (MEM) based on an encoder-decoder architecture is designed, employing a hierarchical modeling strategy and constructing a multi-scale pathway consisting of local window Mamba and global Mamba to achieve local detail enhancement and global brightness restoration. On this basis, a dual-stream fusion color modulation (DFCM) module is introduced, which captures horizontal and vertical spatial dependencies through bidirectional convolutional blocks and integrates global-local features using a lightweight attention mechanism. Simultaneously, channel gating and color modulation mechanisms are applied to adaptively restore color information and fine image details. Finally, total variation regularization is introduced to constrain the illumination map, preventing structural inconsistency caused by over-enhancement. Experimental results show that the proposed method achieves 24.370 dB PSNR and 0.853 SSIM on the LOLv1 dataset, significantly outperforming existing methods. The method demonstrates notable advantages in illumination correction, noise suppression, and detail preservation, while also exhibiting strong generalization capability for real-world low-light scenarios.

Keywords low-light image enhancement; state space; homomorphic filtering; color modulation module; total variation regularization

在弱光环境下采集的图像往往伴随严重的照度不均、噪声干扰和细节缺失,这些固有退化不仅降低了视觉质量,还会对后续的检测、识别与分析等高层视觉任务造成不利影响,进而制约了其在工业检测^[1]、医疗影像^[2]和航空遥感^[3]等领域的应用。尽管许多方法已经在亮度恢复和细节增强方面取得了显著进展,但如何在保证高质量增强效果的同时兼顾计算效率、鲁棒性以及跨场景适应能力,仍然是当前亟需解决的关键问题。

传统低照度图像增强方法包括直方图均衡化^[4]和基于 Retinex 理论的方法^[5],前者通过调

整全局灰度分布提升亮度,后者则借助光照与反射分量分离提升对比度。尽管在提升整体亮度与对比度方面取得了一定成效,但此类方法依赖人工设计规则,在复杂场景下往往表现不足,容易引入噪声放大与细节失真。近年来,随着深度学习的快速发展,低照度图像增强逐渐进入数据驱动阶段。Lore 等人提出的 LLNet^[6]作为首个基于深度自编码器的端到端模型,能够自动学习非线性映射关系以改善低照度图像质量。随后,Wei 等人提出 RetinexNet^[7],将 Retinex 理论与深度分解网络结合,实现了对照度与反射分量的分离与增

强,显著提升了可解释性。此后,研究者围绕 Retinex 与深度学习的结合展开了系列工作。王萍等人尝试采用多尺度分解与双边滤波策略对照度与反射分量进行分离与增强^[8],以提高细节恢复能力;Liu 等人提出的 RUAS 框架通过架构搜索生成轻量化子网络^[9];Ma 等人进一步提出 SCI 模型^[10],在提升灵活性与无监督学习能力方面取得进展,但在多光源混合场景下仍存在局限。近几年,Transformer 结构凭借其强大的建模能力被广泛应用于低照度增强。Xu 等人提出 SNR-aware-Transformer^[11],通过长程依赖建模提升了极暗区域的信号补偿;Pei 等人提出 FFTFormer^[12],结合空间域与频域特征以抑制噪声;Wen 等人进一步提出基于照度引导的双注意力 Transformer^[13],有效缓解了细节模糊与色彩偏移问题。尽管这些方法在性能上取得显著提升,但其普遍依赖多头自注意力机制,导致参数数量和计算复杂度随输入分辨率呈二次增长,难以在实时或移动端部署。为此,一些学者尝试结合多尺度分解与上下文 Transformer^[14],以在性能与效率间寻求平衡,但计算开销依然是瓶颈。在最新研究中,结合状态空间模型(SSM)的低照度图像增强方法成为新的趋势。Zou 等人提出 Wave-Mamba^[15],利用小波变换实现无损下采样并结合改进状态空间模型以增强超高清图像,但在应对非自然噪声时鲁棒性不足。Bai 等人则提出 Retinex-Mamba^[16],将 Retinex 理论与 Mamba 的高效建模能力结合,在增强效果上取得进展,但对色彩的恢复仍差强人意,具体表现为局部饱和度不稳定、跨通道色彩一致性偏弱,尤其在强非均匀光照或极端低照度场景下易产生色偏现象,限制了其在实际视觉感知质量

上的进一步提升。

总体而言,传统方法依赖人工先验,难以适应复杂场景变化;深度学习方法虽然具备更强的表达与建模能力,但往往存在计算开销大、对噪声敏感及可移植性不足的缺陷。尤其是在实际应用场景中,对模型的轻量化和快速推理能力提出了更高要求。在这一背景下,许多研究者开始关注如何融合不同领域的优势^[17-18],一方面引入物理先验知识,以提升模型的可解释性与稳定性,另一方面结合高效的深度学习架构^[19-20],在保证性能的同时降低计算负担。此外,如何通过自适应的模块设计应对多光源干扰、复杂噪声分布与跨域数据差异,也是当前低照度图像增强研究的重要方向^[21-22]。受此启发,本文构建了一种光照引导状态空间建模的低照度图像增强方法(light-prior driven low-light enhancement network, LPD-Net),在保证增强效果的同时实现更好的鲁棒性。

1 LPD-Net 方法

本文提出的 LPD-Net 方法由 2 部分组成,即光照先验模块(illumination prior module, IPM)与 Mamba 优化增强模块(Mamba enhance module, MEM)整体网络结构如图 1 所示。

在图 1 中,IPM 模块基于 Retinex 理论构建并与同态滤波先验融合,用于对输入图像的光照分量进行估计与平滑校正。此外,为了同时实现结构恢复与噪声抑制,本文设计了基于状态空间建模与多尺度融合的 MEM 模块,该模块采用对称的编码器-解码器结构,通过分层建模策略实现从局部纹理到全局结构的增强。




图 1 LPD-Net 整体框架

Fig. 1 The framework of LPD-Net

1.1 光照先验模块 IPM

低照度图像通常存在明显的亮度不均与色彩偏差问题。传统的 Retinex 分解增强方法虽能在一定程度上提升整体亮度,但在处理非均匀光照及强反射区域时,往往难以有效抑制产生的伪影与失真。为改善这一问题,本文在光照建模中引入同态滤波,通过频域增强实现低频色彩结构的均衡与高频纹理细节的保留。具体而言,低照度图像 I 通过同态滤波器(homomorphic filter, HF)进行频域归一化处理并获得光照归一化图像 I_h 。其中,同态滤波采用高斯型高通滤波器,其截止频率 D_0 决定了低频光照分量与高频反射分量的分离尺度,是影响光照先验建模效果的关键参数。本文通过在 LOLv1 数据集上的消融实验对不同截止频率进行比较,综合性能表现与稳定性分析,最终将截止频率设置为 15。低频增益与高频增益分别设置为 0.5 与 2.0,在抑制非均匀光照的同时避免高频噪声的过度放大。需要指出的是,增益参数主要用于调节频域增强幅度,其变化对整体性能影响相对有限,且能在后续可学习网络中得到一定程度的自适应补偿,因此,本文重点分析对光照结构建模影响更为显著的截止频率参数。随后,将其与低照度图在通道维度上拼接,形成包含光照与结构信息的复合输入张量,再经过 1 个 1×1 卷积层实现通道映射,最后,通过 1 个 5×5 深度可分卷积层和 1 个 1×1 卷积层进一步提取局部光照分布特征,并生成对应的中间特征 I_{illu} 与光照图 I_{light} , I_{illu} 用于引导后续增强阶段的特征恢复,其具体操作过程可描述为

$$I_{\text{illu}} = \text{DepthConv}_{5 \times 5}(\sigma(W_1 * [I, \text{Homo}(I)] + b_1)) \quad (1)$$

式中: I_{illu} 为中间特征; $\text{DepthConv}_{5 \times 5}$ 表示核大小为 5×5 的深度可分离卷积操作; $\sigma(\cdot)$ 为激活函数; $I \in \mathbf{R}^{3 \times H \times W}$ 为输入低照度彩色图像; $\text{Homo}(I)$ 为同态滤波操作; W_1, b_1 为可学习卷积与偏置; $[\cdot, \cdot]$ 表示按通道拼接; $*$ 为卷积运算。

1.2 Mamba 优化增强模块 MEM

为解决低照度图像经 IPM 模块初步增强后,反射分量仍存在细节模糊与噪声放大的问题,本文设计了 MEM 模块,通过光照特征引导实现噪声抑制与亮度自适应增强。整体结构可划分为 3 个阶段:在特征嵌入与编码阶段,特征经 3×3 卷积进行浅层特征提取后送入编码器,每个编码层均嵌入了窗口化光照融合块(illumination fusion

block-W, IFB-W),下采样操作采用 4×4 、步长为 2 的卷积以扩展感受野并提取多尺度上下文信息;在瓶颈层阶段,网络引入全局光照融合块(illumination fusion block-G, IFB-G),实现光照分布与结构特征的全局联合建模;在解码阶段,通过转置卷积逐步上采样以恢复空间分辨率,并与对应编码层特征进行跳跃连接,利用 1×1 卷积完成通道融合并抑制维度冗余。最终,输出层经 3×3 卷积生成增强结果,并通过残差连接将输入叠加至输出,有效防止过度增强与色彩偏移。全局光照融合块和窗口化光照融合块分别如图 2、3 所示。




图2 全局光照融合块

Fig. 2 Illumination fusion block-global SS2D




图3 窗口化光照融合块

Fig. 3 Illumination fusion block-WindowSS2D

如图 2、3 所示,特征输入到光照融合模块后,首先通过 1×1 卷积对齐维度,再与中间特征一同送入双流融合色彩调制模块(dual-stream fusion-color modulation, DFCM),实现亮度自适应与色彩校正。随后在 MEM 模块中 U 型网络的第 1~2 层引入窗口化二维选择性状态扫描模块(WindowSS2D)扫描机制,在第 3 层引入二维选择性状态扫描模块(SS2D),增强几何结构信息。最后,经过归一化前馈网络对特征进行非线性映射与通道交互,通过残差连接与输入特征叠加,实现特征的深层表达与信息保留。

由于光照估计阶段的光照分支主要负责建模全局分布,光照特征更倾向于低频全局分量;反射分支则聚焦于结构细节的恢复,反射特征包含高频纹理与噪声信息。因此,若直接将 2 类特征进行简单融合,易导致亮度过度增强与颜色偏移。

为实现低照度图像的光照一致性恢复与纹理细节增强的协同优化,本文在 IFB 块中提出 DFCM 模块。双流融合色彩调制块如图 4 所示,该模块经过层归一化后,通过光照引导(illu-fea)的轻量注意力块(lite attention block, LAB)实现远距离特征依赖的动态加权。同时,通过垂直-水平卷积块(vertical horizontal conv, VHC)实现方向性特征增强,补充局部结构与边缘纹理。最后,通过颜色调制策略实现反射层的亮度自适应与色彩校正。具体而言,LAB 块只采用少量注意力头,利用光照引导特征 I_{illu} 作为查询,上一阶段的输出特征 F_R 作为键值,实现跨特征域的注意力映射,公式为

$$A = \text{Attention}(F_R, I_{\text{illu}}) \quad (2)$$

式中: A 为注意力分支输出特征,该注意力分支能够在光照引导下突出反射层重要区域,同时抑制噪声增强。




图 4 双流融合色彩调制块

Fig. 4 Dual-stream fusion color modulation

VHC 块通过与轻量化状态空间近似的垂直卷积与水平卷积捕捉空间依赖,如下式所示。

$$F_V = \text{Conv}_{k \times 1}(F_R), F_H = \text{Conv}_{1 \times k}(F_R) \quad (3)$$

$$F_C = F_V + F_H \quad (4)$$

式中: $\text{Conv}_{k \times 1}$ 、 $\text{Conv}_{1 \times k}$ 分别代表垂直方向和水平方向的卷积算子; F_V 、 F_H 表示 2 个方向的特征; F_R 为 IPM 模块的输出特征; F_C 表示卷积分支合并后的特征。为平衡两分支在亮度与纹理上的贡献,DFC 模块引入通道自适应融合,如下式所示:

$$F_{\text{out}} = G_{\text{gate}} \odot A + (1 - G_{\text{gate}}) \odot F_C \quad (5)$$

$$G_{\text{gate}} = \sigma(\text{Conv}_{1 \times 1}[A, F_C]) \quad (6)$$

式中: F_{out} 为 LAB 与 VHC 融合后的特征; G_{gate} 为通道级融合权重; $\odot$ 为按通道逐元素相乘; A 为注意力分支输出特征; σ 为 Sigmoid 激活函数; $\text{Conv}_{1 \times 1}$ 表示核大小为 1×1 的卷积操作; $[\cdot, \cdot]$ 表示按通道拼接。该融合操作保证了注意力分支与双向卷积分支在特征层面的自适应组合,增强了网络在不同光照区域的响应能力。

如图 4 所示,为实现对低照度图像颜色偏差

的自适应调节,在 DFCM 块中引入色彩调制模块(ColorFiLM),从而在特征空间中对不同通道施加可学习的仿射调制。具体而言,对融合特征 F_{out} ,首先依据图像的亮度提取调制参数,并以通道为单位对特征进行逐像素变换,其数学表达式可定义为

$$F'_c = (W_\gamma z + b_\gamma) F_{\text{out}} + W_\beta z + b_\beta \quad (7)$$

式中: F'_c 为 ColorFiLM 的输出, c 为通道索引; W_γ 、 W_β 为可学习的权重矩阵,能够建模通道间的全局协同关系; z 为对光照特征进行全局池化后的结果; b_γ 、 b_β 是偏置向量。

如图 5、6 所示,引入的 SS2D 和 WindowSS2D 扫描方式,可以实现从全局与局部 2 个尺度的互补建模。SS2D 采用四方向非重叠扫描策略,实现对整个特征图的全局序列化建模。首先采用深度可分离卷积提取局部特征并降低计算量;随后通过四向扫描机制对特征进行空间依赖建模,实现跨行列的上下文信息捕获,增强局部与全局的特征交互;最后应用层归一化和 SILU 激活函数,在保证梯度稳定的同时引入非线性映射。相比之下,WindowSS2D 模块在保留 SS2D 核心结构的同时,针对滑动窗口机制进行了优化。该模块首先对输入特征进行适当的填充(padding),保证窗口划分时边界信息的完整性;随后对特征进行窗口划分(partition),在每个小窗口内独立执行四方向扫描操作,实现局部上下文建模;最后通过去除填充(remove padding)操作恢复原始特征尺寸,并继续进行归一化和激活处理。




图 5 二维选择性状态扫描模块

Fig. 5 SS2D




图 6 窗口化二维选择性状态扫描模块

Fig. 6 WindowSS2D

1.3 损失函数设计

1.3.1 联合像素损失

联合像素损失通过结合 L_1 损失与结构相似性 (SSIM) 损失,在像素级和结构级约束增强图像质量。其计算公式为

$$L_{\text{pixel}} = \lambda_{L_1} \cdot L_1(I_{\text{pred}}, I_{\text{gt}}) + \lambda_{\text{SSIM}} \cdot L_{\text{SSIM}}(I_{\text{pred}}, I_{\text{gt}}) \quad (8)$$

$$L_1 = \frac{1}{N} \sum_{i=1}^N |I_{\text{pred}}^i - I_{\text{gt}}^i| \quad (9)$$

$$L_{\text{SSIM}} = 1 - \frac{(2\mu_{\text{pred}}\mu_{\text{gt}} + C_1)(2\sigma_{\text{pred} \times \text{gt}} + C_2)}{(\mu_{\text{pred}}^2 + \mu_{\text{gt}}^2 + C_1)(\sigma_{\text{pred}}^2 + \sigma_{\text{gt}}^2 + C_2)} \quad (10)$$

式中: $I_{\text{pred}}, I_{\text{gt}}$ 分别为网络预测图像与真实图像; $\lambda_{L_1}, \lambda_{\text{SSIM}}$ 为权重系数,按照经验设置为 1.0 和 0.35; L_1 表示平均绝对误差,用于约束像素亮度恢复; L_{SSIM} 表示结构相似性损失,用于保持边缘与纹理结构。

1.3.2 全变分损失

利用 Retinex 分解得到的光照分量在缺少约束时,会在光照图上产生高频噪声,进而影响最终的增强结果。因此为了约束光照图的平滑性并抑制噪声,引入全变分损失,其计算公式为

$$L_{\text{TV}} = \sum_{i,j} [(I_{\text{light}(i+1, j)} - I_{\text{light}(i, j)})^2 + (I_{\text{light}(i, j+1)} - I_{\text{light}(i, j)})^2] \quad (11)$$

式中: I_{light} 表示网络输出的光照图。

2 实验结果与分析

2.1 实验细节

本文在弱光图像增强基准数据集 LOLv1、LOLv2-real 与 LOLv2-synthetic 上进行训练、验证与测试。为提升模型的泛化能力,训练阶段对低照度与对应正常光图像施加随机几何增强,并将图像裁剪为 128×128 像素的无重叠图像块。优化器采用 Adam,初始学习率为 2×10^{-4} ,并使用两阶段学习率调度策略:前期保持固定学习率,后期通过带重启的余弦退火机制将学习率逐步衰减至 1×10^{-6} 。训练总迭代步数设定为 1.5×10^5 。损失函数采用全变分损失、 L_1 像素损失与 SSIM 结构损失的加权组合对模型进行优化。验证与测试阶段对整幅图像进行分块推理,并将所有重建块的平均 PSNR 与 SSIM 作为最终图像质量评价指标。所有实验在 NVIDIA RTX4070 Ti GPU 环

境下完成,代码基于 PyTorch 1.13 实现。

2.2 低照度图像增强数据集

为全面验证所提出方法的有效性与泛化能力,本文在 LOLv1、LOLv2-real 和 LOLv2-synthetic 公开低照度图像增强数据集上进行实验评估。LOLv1 数据集包含 485 对训练样本和 15 对测试样本,图像真实采集于室内外复杂光照环境,其噪声与欠曝光等退化均来源于真实成像过程,常用于评估模型在真实低照度场景下的基础恢复能力。LOLv2-real 进一步扩展了真实数据规模,涵盖更丰富的弱光场景与成像条件,共包含 589 对训练样本和 100 对测试样本,具有更复杂的分布偏差,用于检验模型在多因素退化条件下的鲁棒性。相比之下,LOLv2-synthetic 基于正常光图像通过物理退化模型合成,包含 900 对训练样本和 100 对测试样本,其退化过程可控且分布一致性较高,主要用于分析模型对不同退化类型的建模与学习能力。

2.3 评价指标

在客观评价指标方面,本文采用图像增强与重建领域中最具代表性的峰值信噪比 (peak signal-to-noise ratio, PSNR) 和结构相似性指数 (structural similarity index measure, SSIM) 对模型性能进行量化评估^[23-24]。PSNR 主要用于衡量增强结果与参考图像之间的逐像素误差,是基于图像均方误差 (MSE) 计算得到的全参考质量指标,其数值越高表明重建图像与真实图像越接近,失真越小。因此,PSNR 能够有效反映增强算法在细节恢复与噪声抑制方面的能力,然而,PSNR 仅从像素级精度出发,并不能充分反映人眼视觉感知特性,本文进一步采用 SSIM 作为补充评价指标。SSIM 从亮度、对比度与结构一致性 3 个方面构建图像质量评价模型,更符合人眼对图像质量的主观判断规律。

2.4 不同方法的对比实验

为验证本文方法的有效性,在 LOLv1、LOLv2-real 以及 LOLv2-synthetic 数据集上与低照度图像增强方法 MBLLEN^[25]、KinD^[26]、KinD + ^[27]、ZeroDCE^[28]、EnlightenGAN^[29]、MIRNet^[30]、RetinexFormer^[31]、LLFormer^[32]、MBPNet^[33]、RetinexMamba^[16]、LCDBNet^[21]、MRUNet^[34]、SCFR-WLMB^[35] 进行比较,所有的方法均由作者提供的公开代码在推荐配置下实现。评价指标采用 PSNR 和 SSIM,在 3 个基准数据集上的实验结果如表 1 所

示。可见,本文方法在 3 个数据集上取得了优秀 的性能。

表 1 在 3 个基准数据集上低照度图像增强算法的性能比较结果

Tab. 1 Comparison results of different LLIE methods on the LOLv1 , LOLv2-real and LOLv2-synthetic databases

方法	年份	LOLv1		LOLv2real		LOLv2-synthetic	
		PSNR ↑	SSIM ↑	PSNR ↑	SSIM ↑	PSNR ↑	SSIM ↑
MBLLEN ^[25]	2018	18. 825	0. 771	17. 973	0. 702	22. 046	0. 898
KinD ^[26]	2019	17. 650	0. 775	14. 740	0. 641	13. 290	0. 578
KinD + + ^[27]	2020	21. 300	0. 823	19. 087	0. 817	21. 170	0. 881
ZeroDCE ^[28]	2020	14. 861	0. 559	16. 059	0. 580	17. 712	0. 815
EnlightenGAN ^[29]	2021	17. 480	0. 651	15. 513	0. 770	16. 570	0. 734
MIRNet ^[30]	2022	22. 652	0. 783	19. 520	0. 737	23. 481	0. 917
Retinexformer ^[31]	2023	23. 466	0. 827	21. 530	0. 834	26. 304	0. 942
LLFormer ^[32]	2023	23. 529	0. 814	21. 301	0. 801	24. 038	0. 909
MBPNet ^[33]	2023	22. 880	0. 834	<u>22. 295</u>	0. 839	25. 340	0. 932
RetinexMamba ^[16]	2024	24. 025	0. 827	22. 453	0. 844	26. 439	<u>0. 947</u>
LCDBNet ^[21]	2024	<u>24. 206</u>	<u>0. 850</u>	21. 186	0. 808	24. 617	0. 935
MRUNet ^[34]	2025	23. 963	0. 823	21. 930	0. 857	—	—
SCFR-WLMB ^[35]	2025	23. 270	0. 811	21. 430	0. 834	23. 85	0. 916
本文方法	2026	24. 370	0. 853	22. 243	<u>0. 853</u>	<u>26. 335</u>	0. 947

注:加黑数值表示最优;下划线数值表示次优。

在 LOLv1 数据集上,本文方法取得 24. 370 dB 的 PSNR 和 0. 853 的 SSIM,优于包括 RetinexFormer、LLFormer、MBPNet 以及近期的 RetinexMamba 在内的大部分先进方法。该结果验证了所提方法在抑制低照度噪声累积、保持结构边缘完整性方面的有效性。在更具挑战性的 LOLv2-real 数据集上,本文方法达到 22. 243 dB/0. 853 的性能,与 RetinexMamba 相当,并在结构相似度上略具优势,该结果主要归因于 2 种方法在全局依赖建模机制上的内在相似性:RetinexMamba 通过状态空间模型增强长程建模能力,而本文方法则在光照先验约束下,结合全局感知与多尺度特征融合,有效建模复杂光照分布。在真实噪声与非均匀光照并存的条件下,本文方法依然能够实现稳定的亮度校正与结构保持,进一步验证了模型在复杂退化场景中细节恢复的鲁棒性。在模拟退化场景的 LOLv2-synthetic 数据集中,本文方法获得 26. 335 dB 的 PSNR 和 0. 947 的 SSIM,明显优于 LCDBNet 和 SCFR-WLMB 等近期方法,而部分方法的 SSIM 指标与本文方法较为接近,这主要是由于合成退化过程在结构层面具有较强一致

性,主流方法均能够较好地恢复全局结构,从而使 SSIM 指标趋于饱和。相比之下,本文方法在 PSNR 上的显著优势表明,在应对极端低照度与大范围亮度变化时,具备更强的细节恢复能力。本文方法在多个数据集上均取得稳定领先的性能表现,展现了其在光照校正、噪声抑制和结构保持方面的综合优势。

除了量化评估之外,为进一步验证所提方法的实际增强效果,本文对 3 个数据集中 2 张兼具色彩与光照代表性的典型样本进行了可视化对比分析,如图 7 所示。可以看到,RetinexNet、MBLLEN、EnlightenGAN 出现明显的色偏与亮度失衡,KinD + + 也存在着细节失真的问题,MIRNet 虽然在亮度方面恢复较好,但仍面临局部噪声过大的局限。近几年的方法如 Retinexformer、LLFormer、MBPNet、RetinexMamba 已经取得了较好的视觉效果,然而在细小噪声的恢复与色彩矫正方面还存在着明显不足。相比之下,本文的方法不仅实现细节的保留与色彩的还原,还实现了亮度的平衡,有效缓解了过曝和欠曝的问题。




图 7 低照度图像数据集上实验结果图

Fig. 7 Experimental result on the LLIE image databases

2.5 消融实验

2.5.1 同态滤波先验的有效性

为了验证同态滤波先验(HF)在低照度图像增强任务中的必要性与贡献,本文设计了针对同态滤波先验消融实验。在实验中,彻底移除 HF 模块及其衍生路径,使得模型必须完全依赖深度注意力机制与状态空间建模学习弱光退化规律,从而明确评估 HF 模块对结构恢复、噪声抑制和亮度一致性的贡献。

实验结果如表 2 所示,去除 HF 的模型在 LOLv1、LOLv2-real 以及 LOLv2-synthetic 数据集上出现稳定下降。其中,LOLv1 上 PSNR 下降 0.826 dB;LOLv2-real 上下降 0.25 dB;LOLv2-synthetic 上则下降了 0.435 dB。更值得注意的是,该结果表明,虽然 MEM 模块具备较强的非线性建模能力,但在缺乏对数域光照解耦的情况下,网络难以在早期阶段处理大范围低频照度偏差,导致后续增强模块难以处理大量的噪声,在纹理恢复与边缘增强不稳定。由此可见,HF 在网络中有着重要作用:一方面,对数域处理将全局照度偏移压缩至低幅度,使网络第 1 层卷积避免了过多参数拟合幅值分布,提高训练稳定性;另一方面,HF 提前过滤掉低频照度干扰,使后续处理聚焦于反射结构,

避免状态空间层被噪声污染。

表 2 同态滤波先验消融实验结果

Tab. 2 Homomorphic filtering prior ablation study results

同态滤波先验	PSNR		
	LOLv1	LOLv2-real	LOLv2-syn
×	23.544	21.993	25.900
√	24.370	22.243	26.335

2.5.2 WindowSS2D 与 SS2D 的策略对比

为了系统性分析网络中空间状态建模方式的影响,本研究针对光照融合模块(IFA)的扫描策略开展了一系列消融实验。原始结构采用浅层窗口化扫描和深层全局扫描的分层设计,其中浅层的 WindowSS2D 负责局部弱光噪声抑制与细节保持,而深层的 SS2D 负责全局语义与光照一致性建模。为了验证该分层扫描设计的必要性,本文构建了 2 个对照版本。首先是完全全局扫描策略(All-Global),即将浅层 WindowSS2D 全部替换为 SS2D;其次是完全窗口扫描策略(All-Window),即将深层 SS2D 全部替换为 WindowSS2D,并消除跨尺度全局状态建模路径。三者保持模型深度、特征维度、参数规模一致,仅改变扫描策略,以排除结构复杂度因素的影响。

实验结果如表 3 所示, All-Global 模型在 LOLv1 上的 PSNR 相较原始结构略降 0. 066 dB, 但在 LOLv2-real 与 LOLv2-synthetic 上分别提升 0. 017 dB 和 0. 245 dB。该结果表明, SS2D 在深层具有较强的长程建模能力, 但在浅层直接引入全局状态传播易导致噪声跨区域耦合放大, 从而在噪声较强的 LOLv1 数据集上出现轻微性能退化, 而在退化更规则或噪声较弱的 LOLv2 数据集上, 全局依赖建模有助于整体亮度结构恢复, 因而性能得到提升。

表 3 扫描策略消融实验结果
Tab. 3 Scan strategy ablation study results

网络设置			PSNR		
第 1 层	第 2 层	第 3 层	LOLv1	LOLv2-real	LOLv2-syn
√	√	√	23. 828	21. 844	26. 428
×	×	×	24. 304	22. 260	26. 580
√	√	×	24. 370	22. 243	26. 335

注:“√”表示使用 WindowSS2D;“×”表示使用 SS2D。
综上所述, 分层扫描策略显著优于单一扫描机制, WindowSS2D 与 SS2D 形成互补关系。更加验证了低照度图像增强并非依赖单纯的局部或全局建模, 而是更需要深浅特征在不同阶段对应不同的空间建模能力。因此, 本文提出的混合扫描策略不仅在性能上优于 2 种单一结构, 其设计逻辑也更符合低照度图像的退化特性。

2. 5. 3 双流色彩调制模块的有效性

为验证所提 DFCM 模块在弱光图像增强任务中的贡献, 本文设计了针对其去除后的对照消融实验。具体而言, 去除了双流融合色彩调制模块并使用轻量化替代版本, 为保持输入输出形态完全一致, 本文仅采用 1 × 1 卷积降维 + 深度可分离卷积 + 点卷积的单支路浅层映射对输入特征进行处理, 不再执行基于光照特征的动态融合, 使网络参数规模变化可控, 实验结果如表 4 所示。

表 4 双流色彩调制模块消融实验结果
Tab. 4 DFCM ablation study results

双流融合色彩 调制块	PSNR		
	LOLv1	LOLv2-real	LOLv2-syn
×	22. 160	21. 045	25. 185
√	24. 370	22. 243	26. 335

本文在 LOLv1、LOLv2-real 与 LOLv2-synthetic 公开基准数据集上开展消融实验, 并采用 PSNR

相反, All-Window 模型在 LOLv1 与 LOLv2-real 上的 PSNR 分别下降 0. 542 dB 和 0. 399 dB, 仅在 LOLv2-synthetic 上获得 0. 093 dB 的小幅提升。该现象说明, 完全窗口化扫描在真实场景中难以有效建模大尺度亮度变化与复杂噪声分布, 过强的局部约束削弱了网络对长程依赖与全局亮度一致性的建模能力, 导致性能下降, 而在退化过程更规则、噪声分布更均匀的合成数据上, WindowSS2D 对局部结构的高效建模反而更具优势。

作为定量评价指标, 系统分析 DFCM 模块对整体性能的影响。实验结果表明, 当移除 DFCM 模块时, 模型性能出现显著下降, 在 3 个数据集上的 PSNR 分别降低至 22. 160 dB、21. 045 dB 和 25. 185 dB, 表明模型在光照恢复与细节重建方面受到明显制约。相比之下, 引入 DFCM 后的完整模型在 3 个数据集上的 PSNR 分别提升至 24. 370 dB、22. 243 dB 和 26. 335 dB, 在不同类型的低照度场景中均取得稳定且显著的性能增益。上述结果充分验证了 DFCM 在复杂光照分布与噪声干扰条件下对结构信息保持与色彩一致性增强的有效性。

2. 6 泛化实验

为进一步评估不同方法在真实场景下的泛化能力, 本文在由 108 MP + 8 MP + 2 MP 多摄像头手机系统采集的真实低照度图像上进行了可视化对比分析, 如图 8、9 所示。图 8 所选示例来自光照极为不足的室外环境, 该类场景通常同时伴随光照分布高度不均、色彩偏移显著以及欠曝光与过曝光区域并存等问题。图 9 所选示例来自光照极弱的室内环境, 该类场景多为封闭空间或局部遮挡条件下成像, 整体亮度水平较低, 暗区域面积占比高, 并且噪声干扰更为显著。这 2 类场景对低照度图像增强算法的亮度调节精度与细节保持能力提出了更高要求。




图 8 室外场景下泛化实验结果图
Fig. 8 The generalization results on outdoor scenes




图 9 室内场景下泛化实验结果图
Fig. 9 The generalization results on indoor scenes

从图 8、9 可视化对比结果可以看出,MBPNet 在室外与室内场景中均展现出较强的整体亮度提升能力,但其增强结果在极暗区域仍存在明显的不均匀现象,局部区域亮度提升不足,导致结构细节难以被有效恢复,尤其在室内阴影区域中这一问题更为突出。轻量化方法 IAT^[36] 在对低照度区域进行增强时,虽然能够在一定程度上改善暗部可见性,但由于对噪声建模能力有限,在室内外场景中均引入了较为明显的噪声放大现象,并伴随局部亮度过曝问题,破坏了整体视觉一致性。LCDBNet 在增强过程中倾向于通过平滑操作抑制噪声,但由此产生了较为明显的模糊伪影,使得边缘结构与细节纹理被过度平滑,高频信息和局部结构特征在复杂室外背景及室内纹理区域中均出现不同程度的丢失。相比之下,尽管本文方法在整体亮度提升幅度上并非最优,但在暗区域细节恢复方面表现更为突出。该方法能够有效重建低

照度区域的纹理结构与边缘信息,同时抑制噪声放大与过度平滑,使增强结果在局部结构连续性与细节完整性上明显优于对比方法。由此在亮度提升、噪声抑制与色彩还原之间实现了更为合理的权衡,获得更加稳定且符合人眼感知的视觉效果。实验结果进一步表明,所提出方法在复杂真实光照条件下仍能保持较好的结构与色彩一致性,体现出良好的鲁棒性与环境适应能力。

2.7 模型复杂度与计算效率分析

在低照度图像增强任务中,模型性能的提升往往伴随着网络结构复杂度和参数规模及计算开销的显著增加,这在一定程度上限制了其在实际应用场景中的部署可行性。尤其是在嵌入式设备、移动终端及实时视觉系统中,模型的数量和计算复杂度直接影响推理效率与能耗表现。因此,在保证增强质量的前提下,实现模型性能与参数规模的有效平衡,已成为当前弱光图像增强方

法设计中的一项关键挑战。

为评估所提出模型的效率与实际的部署潜力,本文从参数规模与计算复杂度(GFLOPs) 2 个维度将所提方法与多种主流低照度图像增强模型进行对比分析。如图 10 所示,其中,横轴表示模型参数量,纵轴表示重建性能指标 PSNR,气泡面积及其标注数值反映模型的计算复杂度。可以观察到,本文方法在参数量显著低于 LLFormer 的条件下,依然取得了最高的 PSNR 表现,体现出较高的参数利用效率。进一步结合计算复杂度分析可知,尽管部分方法在参数规模上相对轻量,如 MBPNet,但其 GFLOPs 却明显偏高,表明网络在特征提取或增强过程中存在较多冗余计算,未能将计算资源有效转化为性能提升。相比之下,所提模型在保持中等参数规模的同时,将计算复杂度控制在较为合理的范围内,使性能提升主要来源于有效特征建模而非计算量堆叠,从而在参数量、GFLOPs 与恢复性能三者之间实现了更优的整体折中。




图 10 模型复杂度与计算效率分析结果

Fig. 10 Results of model complexity and computational efficiency analysis

此外,即便面对如 MIRNet 这类参数量超过 30 MB、计算复杂度极大的大规模网络,其 PSNR 表现仍未能超越本文方法,进一步表明高质量的低照度图像增强并不必然依赖于高参数量或高计算成本。上述结果充分验证了本文所提出的层次化建模与高效特征增强策略在抑制冗余计算、提升特征表达效率方面的有效性。综上,本文方法在增强性能、参数规模与计算效率之间取得了良好平衡,显著降低了对计算资源的依赖,为资源受限设备和实时视觉系统中的高质量弱光图像增强提供了一种具有实际部署潜力的高效设计范式。

3 结语

本文提出了一种光照先验引导的低照度图像增强方法 LPD-Net。该方法结合同态滤波生成光照归一化特征,实现非均匀光照的全局校正。采用分层建模策略,充分整合空域与频域信息,同时通过轻量化卷积与注意力机制实现全局与局部特征协同融合,并通过通道门控与色彩调制机制自适应恢复细节与色彩。大量实验结果表明,所提方法在多个公开低照度图像增强数据集上均优于现有方法,在光照校正、噪声抑制及细节保真方面表现出显著优势。尤其在中度至重度低照度且光照分布不均的室内外场景中,LPD-Net 能够在亮度提升与结构保真之间取得良好平衡,生成更加自然且稳定的增强结果。

尽管所提出的 LPD-Net 方法在光照适应性和多尺度特征融合方面取得了明显提升,但仍存在一些局限性:对于极端低照度或复杂噪声条件下的图像,细节恢复仍有优化空间;模型在高分辨率图像处理时的计算成本和内存占用仍较高。未来我们将探索自适应注意力或动态窗口机制,进一步增强模型对局部纹理和全局结构的协调建模能力,同时,设计轻量化网络结构与高效推理策略,以提升在大规模或实时低照度增强场景下的适用性与效率。

参考文献

- [1] 董良振,田建艳,杨胜强,等. 基于光照校正和图像融合的零件表面图像增强[J]. 计算机工程,2024, 50(6):245-254.
DONG L Z, TIAN J Y, YANG S Q, et al. Image enhancement of part surface based on illumination correction and image fusion [J]. Computer Engineering, 2024, 50(6): 245-254.
- [2] CHEN T, LYU Q C, BAI L, et al. LighTDiff: Surgical endoscopic image low-light enhancement with T-diffusion[C]//Medical Image Computing and Computer-Assisted Intervention - MICCAI 2024. Cham: Springer, 2024: 369-379.
- [3] 杨允权,刘国宁,孙克文,等. 基于神经网络的飞行器空中侦查时低照度图像增强系统[J]. 机械设计与制造, 2023(9):163-168.
YANG Y Q, LIU G N, SUN K W, et al. Neural network based low-light aerial image enhancement system

- for aerial surveillance by aircraft[J]. *Machinery Design & Manufacture*, 2023(9): 163-168.
- [4] PIZER S M, AMBURN E P, AUSTIN J D, et al. Adaptive histogram equalization and its variations[J]. *Computer Vision, Graphics, and Image Processing*, 1987, 39(3): 355-368.
- [5] 李学明. 基于 Retinex 理论的图像增强算法[J]. *计算机应用研究*, 2005, 22(2): 235-237.
- LI X M. Image enhancement algorithm based on Retinex theory [J]. *Application Research of Computers*, 2005, 22(2): 235-237.
- [6] LORE K G, AKINTAYO A, SARKAR S. LLNet: A deep autoencoder approach to natural low-light image enhancement[J]. *Pattern Recognition*, 2017, 61: 650-662.
- [7] WEI C, WANG W J, YANG W H, et al. Deep retinex decomposition for low-light enhancement [EB/OL]. (2018-08-14) [2025-12-05]. <https://arxiv.org/abs/1808.04560>.
- [8] 王萍,孙振明. 多级分解的 Retinex 低照度图像增强算法[J]. *计算机应用研究*, 2020, 37(4): 1204-1209.
- WANG P, SUN Z M. Multi-level decomposition Retinex low-light image enhancement algorithm[J]. *Application Research of Computers*, 2020, 37(4): 1204-1209.
- [9] LIU R S, MA L, ZHANG J A, et al. Retinex-inspired unrolling with cooperative prior architecture search for low-light image enhancement [C] // 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville: IEEE, 2021: 10556-10565.
- [10] MA L, MA T Y, LIU R S, et al. Toward fast, flexible, and robust low-light image enhancement [C] // 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans: IEEE, 2022: 5627-5636.
- [11] XU X G, WANG R X, FU C W, et al. SNR-aware low-light image enhancement [C] // 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans: IEEE, 2022: 17693-17703.
- [12] PEI X, HUANG Y D, SU W J, et al. FFTFormer: A spatial-frequency noise aware CNN-Transformer for lowlight image enhancement [J]. *Knowledge-Based Systems*, 2025, 314: 113055.
- [13] WEN Y J, XU P, LI Z H, et al. An illumination-guided dual attention vision transformer for low-light image enhancement[J]. *Pattern Recognition*, 2025, 158: 111033.
- [14] 徐文晨,樊佳庆,宋慧慧. 基于上下文 Transformer 的低光照图像增强网络 [J]. *计算机与数字工程*, 2023, 51(1): 237-244.
- XU W C, FAN J Q, SONG H H. Low lighting image enhancement network based on contextual Transformer [J]. *Computer and Digital Engineering*, 2023, 51(1): 237-244.
- [15] ZOU W B, GAO H X, YANG W P, et al. Wave-mamba: Wavelet state space model for ultra-high-definition low-light image enhancement [C] // Proceedings of the 32nd ACM International Conference on Multimedia. Melbourne: ACM, 2024: 1534-1543.
- [16] BAI J S, YIN Y H, HE Q Y, et al. Retinexmamba: Retinex-based mamba for low-light image enhancement [M] // International Conference on Neural Information Processing. Singapore: Springer Nature Singapore, 2025: 427-442.
- [17] CHEN K, ZHANG K B, PANG F F, et al. RMANet: Refined-mixed attention network for progressive low-light image enhancement [J]. *Signal Processing*, 2025, 227: 109689.
- [18] WANG H K, YAN X Y, HOU X S, et al. Extracting noise and darkness: Low-light image enhancement via dual prior guidance[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2025, 35(2): 1700-1714.
- [19] 朱松浩,赵芝芸,王梦灵. 基于轻量残差与亮度感知动态特征融合的低光图像增强网络[J/OL]. *计算机应用*. (2025-09-28) [2025-12-05]. <https://link.cnki.net/urlid/51.1307.TP.20250925.1330.034>.
- ZHU S H, ZHAO Z Y, WANG M L. Lightweight residual and brightness-aware dynamic feature fusion for low-light image enhancement [J/OL]. *Journal of Computer Applications*. (2025-09-28) [2025-12-05]. <https://link.cnki.net/urlid/51.1307.TP.20250925.1330.034>.
- [20] 江泽涛,李塋,黄钦阳,等. 一种基于自校准知识蒸馏的低照度图像增强方法[J/OL]. *计算机辅助设计与图形学学报*. (2025-04-03) [2025-12-05]. <https://link.cnki.net/urlid/11.2925.tp.20250403.1427.004>.
- JIANG Z T, LI K, HUANG Q Y, et al. Self-calibrated knowledge distillation for low-light image enhancement [J/OL]. *Journal of Computer-Aided Design & Computer Graphics*. (2025-04-03) [2025-12-05]. <https://link.cnki.net/urlid/11.2925.tp.20250403.1427.004>.
- [21] WANG H K, YAN X Y, HOU X S, et al. Division

- gets better: Learning brightness-aware and detail-sensitive representations for low-light image enhancement [J]. Knowledge-Based Systems, 2024, 299: 111958.
- [22] LI Y J, ZHANG K B, ZHOU X, et al. Rethinking progressive low-light image enhancement: A frequency-aware tripartite multi-scale network[J]. Neural Networks, 2026, 196: 108351.
- [23] 张凯兵, 张智启, 孟雅蕾. 语义感知下的多尺度 U 型 Swin Transformer 人脸超分辨率方法[J]. 西安工程大学学报, 2025, 39(5): 135-145.
- ZHANG K B, ZHANG Z Q, MENG Y L. Semantic-aware multi-scale U-shaped Swin Transformer for face super-resolution[J]. Journal of Xi'an Polytechnic University, 2025, 39(5): 135-145.
- [24] 王晓华, 侯佳辉, 张凯兵, 等. 渐进式深度网络下盲运动图像去模糊方法[J]. 西安工程大学学报, 2023, 37(3): 74-82.
- WANG X H, HOU J H, ZHANG K B, et al. Progressive deep network for blind motion image deblurring [J]. Journal of Xi'an Polytechnic University, 2023, 37(3): 74-82.
- [25] LYU F, LU F, WU J, et al. MBLEN: Low-light image/video enhancement using CNNs[C]//Proceedings of the British Machine Vision Conference. Newcastle: BMVA Press, 2018, 220(1): 4.
- [26] ZHANG Y H, ZHANG J W, GUO X J. Kindling the darkness: A practical low-light image enhancer[C]//Proceedings of the 27th ACM International Conference on Multimedia. Nice: ACM, 2019: 1632-1640.
- [27] ZHANG Y H, GUO X J, MA J Y, et al. Beyond brightening low-light images[J]. International Journal of Computer Vision, 2021, 129(4): 1013-1037.
- [28] GUO C L, LI C Y, GUO J C, et al. Zero-reference deep curve estimation for low-light image enhancement [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020: 1777-1786.
- [29] JIANG Y F, GONG X Y, LIU D, et al. EnlightenGAN: Deep light enhancement without paired supervision[J]. IEEE Transactions on Image Processing, 2021, 30: 2340-2349.
- [30] ZAMIR S W, ARORA A, KHAN S, et al. Learning enriched features for fast image restoration and enhancement[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(2): 1934-1948.
- [31] CAI Y H, BIAN H, LIN J, et al. Retinexformer: One-stage retinex-based transformer for low-light image enhancement [C] // 2023 IEEE/CVF International Conference on Computer Vision. Paris: IEEE, 2023: 12470-12479.
- [32] WANG T, ZHANG K H, SHEN T R, et al. Ultra-high-definition low-light image enhancement: A benchmark and transformer-based method[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2023, 37(3): 2654-2662.
- [33] ZHANG K B, YUAN C, LI J, et al. Multi-branch and progressive network for low-light image enhancement [J]. IEEE Transactions on Image Processing, 2023, 32: 2295-2308.
- [34] WANG H K, HOU X S, LI J T, et al. Multi-scale Retinex unfolding network for low-light image enhancement[J]. IEEE Transactions on Multimedia, 2025, 27: 5709-5721.
- [35] ZHANG J M, JIANG J, FENG Z J, et al. Learning spatial-channel feature refiners via wavelet-based linear mixed basis for low-light image enhancement [J]. Knowledge-Based Systems, 2025, 330: 114567.
- [36] CUI Z T, LI K C, GU L, et al. You only need 90K parameters to adapt light: A light weight transformer for image enhancement and exposure correction [EB/OL]. (2022-05-27) [2025-12-05]. <https://arxiv.org/abs/2205.14871>.

(编辑 李 静)